

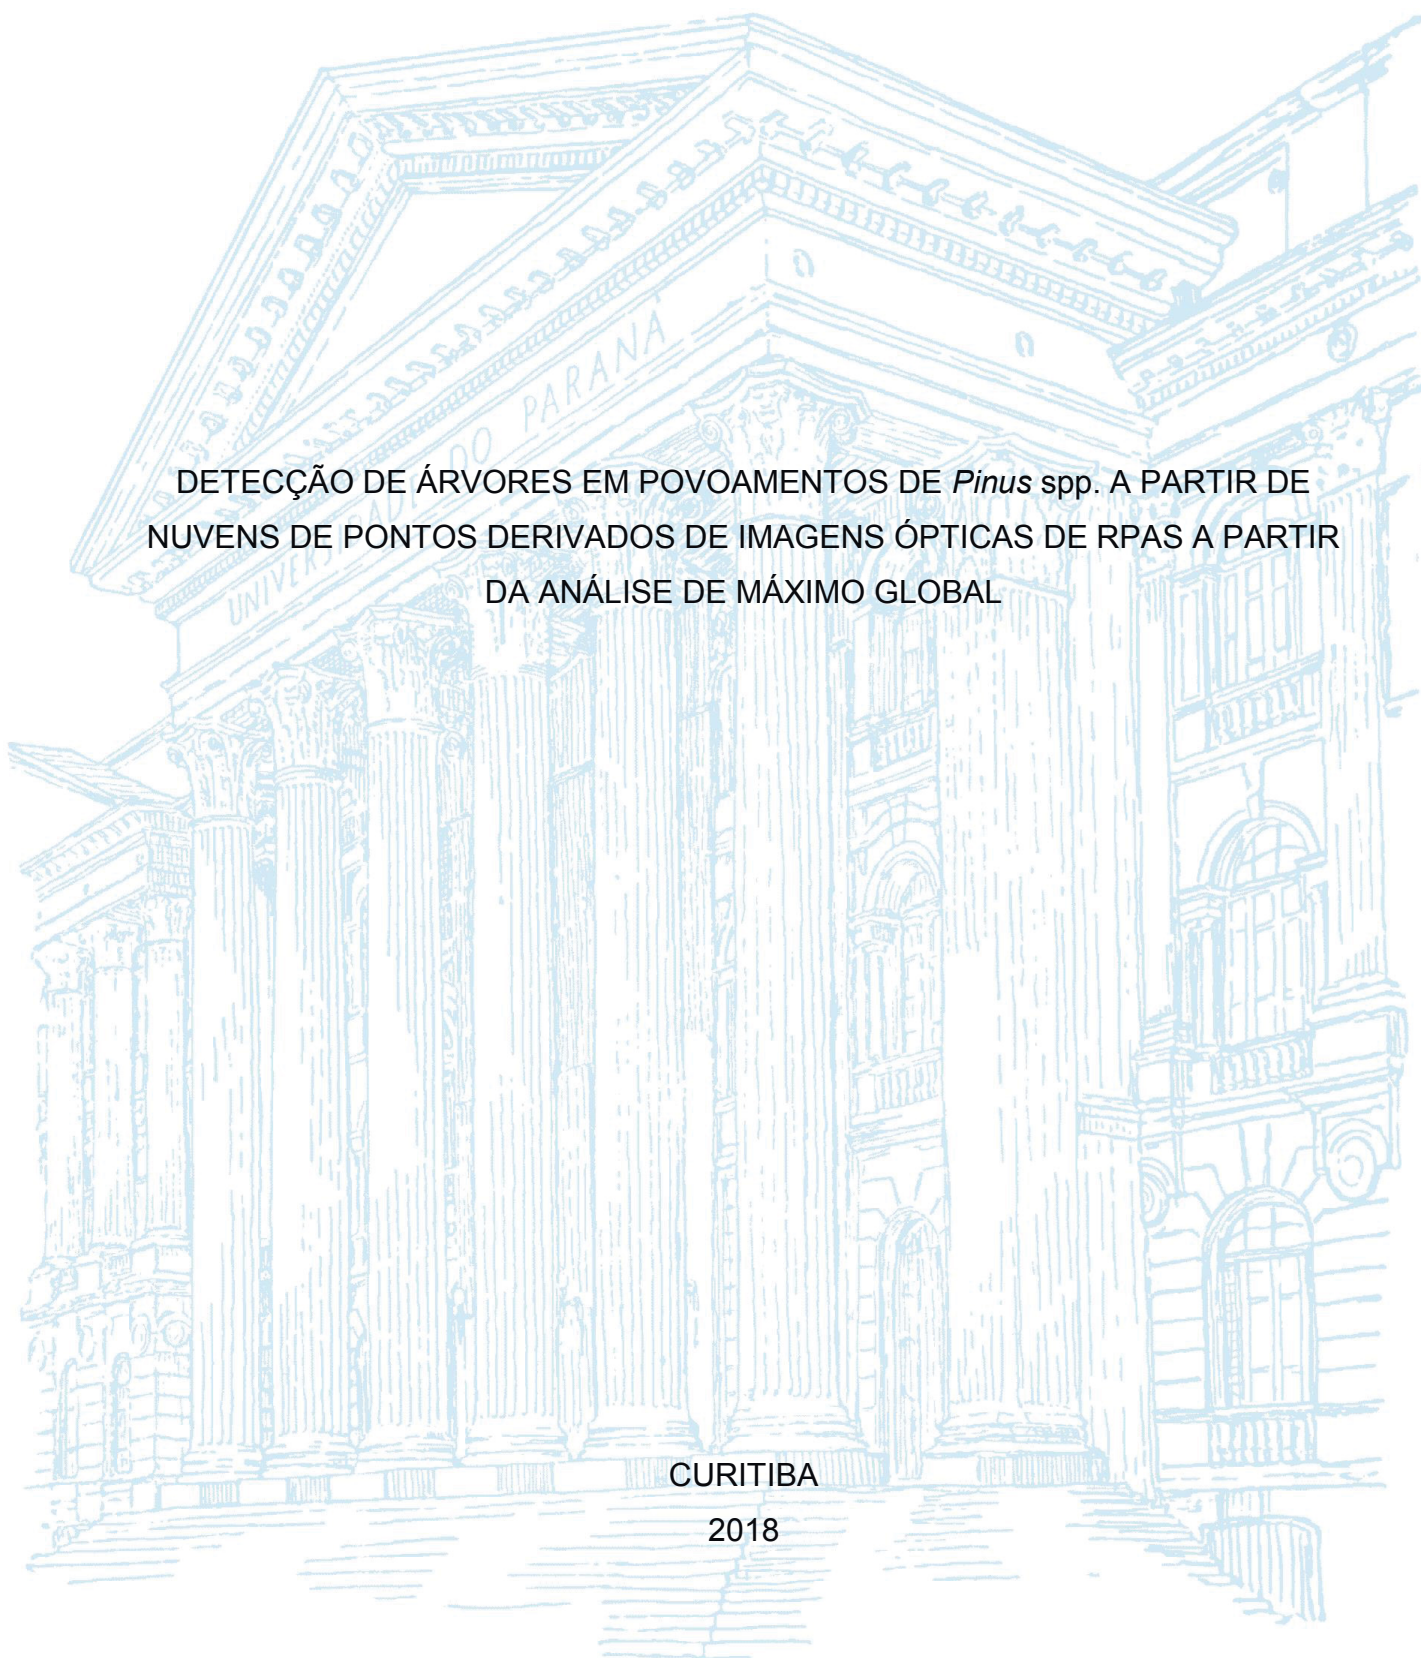
UNIVERSIDADE FEDERAL DO PARANÁ

KÊNIA SAMARA MOURÃO SANTOS

DETECÇÃO DE ÁRVORES EM POVOAMENTOS DE *Pinus* spp. A PARTIR DE  
NUVENS DE PONTOS DERIVADOS DE IMAGENS ÓPTICAS DE RPAS A PARTIR  
DA ANÁLISE DE MÁXIMO GLOBAL

CURITIBA

2018



KÊNIA SAMARA MOURÃO SANTOS

DETECÇÃO DE ÁRVORES EM POVOAMENTOS DE *Pinus* spp. A PARTIR DE  
NUVENS DE PONTOS DERIVADOS DE IMAGENS ÓPTICAS DE RPAS A PARTIR  
DA ANÁLISE DE MÁXIMO GLOBAL

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Florestal, Área de concentração em Manejo Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Florestal.

Orientadora: Professora Dr<sup>a</sup>. Christel Lingnau  
Coorientador: Professor Dr. Daniel Rodrigues dos Santos

CURITIBA

2018

Ficha catalográfica elaborada pela  
Biblioteca de Ciências Florestais e da Madeira - UFPR

Santos, Kênia Samara Mourão

Detecção de árvores em povoamentos de *Pinus spp.* a partir de nuvens de pontos derivados de imagens ópticas de RPAS a partir da análise de máximo global / Kênia Samara Mourão Santos. – Curitiba, 2018.

99 f. : il.

Orientadora: Profa. Dra. Christel Lingnau

Coorientador: Prof. Dr. Daniel Rodrigues dos Santos

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 09/03/2018.


Área de concentração: Manejo Florestal.

1. Sensoriamento remoto. 2. Processamento de imagens – Técnicas digitais. 3. Algoritmos de computador. 4. Levantamentos florestais – Programas de computador. 5. Pinheiro. 6. Teses. I. Lingnau, Christel. II. Santos, Daniel Rodrigues dos. III. Universidade Federal do Paraná, Setor de Ciências Agrárias. IV. Título.

CDD – 634.9028

CDU – 528.8

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160



MINISTÉRIO DA EDUCAÇÃO  
SETOR SETOR DE CIÊNCIAS AGRÁRIAS  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
FLORESTAL

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **KÊNIA SAMARA MOURÃO SANTOS** intitulada: **DETECÇÃO DE ÁRVORES EM POVOAMENTOS DE *Pinus* spp. A PARTIR DE NUVENS DE PONTOS DERIVADOS DE IMAGENS ÓPTICAS DE RPAS A PARTIR DA ANÁLISE DE MÁXIMO GLOBAL**, após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 09 de Março de 2018.

CHRISTEL LINGNAU

Presidente da Banca Examinadora (UFPR)

JORGE ANTONIO SILVA CENTENO

Avaliador Externo (UFPR)

JOÃO ROBERTO DOS SANTOS

Avaliador Externo (INPE)



*Às mulheres que me inspiram:  
Minha mãe, Rose Mary;  
Minha tia, Iris e à minha vizinha Altanir.*

Dedico



## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, ou à energia que rege este universo, por ter me possibilitado chegar aqui, e realizar um dos meus grandes objetivos de vida.

Aos meus pais, Virgílio Kennedy e Rose Mary, por terem me incentivado durante todo o período fora de casa e de minha cidade, e não mediram esforços para que eu tivesse a melhor formação possível.

Aos meus familiares: avós, tios, tias, primos e primas, por terem me dado apoio durante toda a duração do mestrado, e por terem sempre acreditado em mim.

À minha tia e madrinha Iris, por sempre me incentivar a seguir o caminho acadêmico e me ajudar sempre que pode.

Aos meus amigos queridos Adriana Neves, Andreia Andrade, Danilo Souza e Jessica Farias, por estarem comigo nas horas mais alegres e nas mais tristes, sempre me dando conselhos e por acreditarem em mim em todas as circunstâncias.

À minha querida amiga de infância Joyce Monteiro, por me dar tanto apoio e incentivo quando os momentos de incertezas surgiam.

À minha amiga Joelen Viana, por me dar forças para seguir em frente com meus objetivos.

À Yasmim Maia, por ter me incentivando em todas as horas durante a obtenção desta dissertação, e por sempre ter acreditado em mim.

Aos amigos que fiz nesta cidade Aline de Carvalho, Gabriela Noguchi, Reginaldo Ferreira, Susian Becker, Valdecir Borges e tantos outros que me incentivaram e me proporcionaram ótimos momentos de descontração.

À minha querida amiga Pryscylla Komora e seus pais, por terem me acolhido em sua casa quando cheguei nesta cidade, e por todo o carinho adquirido durante minha estadia em sua casa.

Aos colegas do programa de pós-graduação em Engenharia Florestal – UFPR, que compartilharam comigo os diversos momentos no decorrer do curso, e pelos momentos de divertimento e descontração, em especial à minha amiga Fernanda Costa por ter me ajudado e escutado nos momentos mais difíceis durante esta trajetória.

Aos meus colegas de laboratório, pelas ajudas e tantos momentos de descontração.

À professora Dra. Christel Lingnau pela orientação, sábios conselhos e pela confiança depositada em mim durante o desenvolvimento desta dissertação.

Ao professor Dr. Daniel Rodrigues dos Santos, pela coorientação, conselhos e ajudas valiosos.

Ao professor Dr. Richardson, pelos ensinamentos básicos sobre programação, o que me possibilitou atingir o objetivo proposto nesta dissertação, pelas horas de conversas e conselhos.

À empresa Brasil Florestal, especialmente ao Diretor Geral Ataídes Marinheski Filho, por não ter medido esforços em apoiar este projeto, pelos conhecimentos compartilhados e por me incentivar a chegar ao resultado final.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos concedida nos meses de duração deste estudo, que foi imprescindível para concretização do Mestrado no programa de pós-graduação em Engenharia Florestal – UFPR.

*“A vida é muito curta para ser pequena”*

Benjamin Disraeli



## RESUMO

Esta pesquisa teve como objetivo a criação de um algoritmo para detecção automática de árvores a partir de nuvens de pontos 3D gerados de imagens ópticas de RPAS. O algoritmo criado, denominado DAA (Detecção Automática de Árvores), cujo funcionamento baseia-se na metodologia de filtro de máximos globais, foi aplicado em dois tipos de povoamentos florestais de *Pinus spp.*: plantio jovem, de 2 anos de idade e plantio adulto, de 11 anos recém desbastado. Para analisar o potencial de funcionamento do DAA, este foi inicialmente aplicado na nuvem de pontos 3D pré-processada do plantio jovem, de 2 anos de idade. O resultado obtido mostrou-se satisfatório, com 91% das árvores detectadas automaticamente pelo algoritmo. Quando aplicado no plantio adulto, o DAA foi comparado a outro algoritmo de detecção automática de árvores, o ITD (*Individual Tree Detection*), cujo princípio de funcionamento tem como base o método de filtro de máximos locais, o mais utilizado para este objetivo. Ao comparar os dois algoritmos com os métodos de contagem em campo das árvores e contagem por fotointerpretação de ortofoto, o DAA apresentou melhores resultados, com 93% de árvores detectadas corretamente, quando comparado a contagem pela ortofoto e 89% em relação ao censo florestal. Em contrapartida, o ITD apresentou valores de 71% de acertos em relação a ortofoto e 74% em relação ao censo florestal. Portanto, o algoritmo ITD subestimou o número total de árvores do talhão adulto, e o DAA obteve melhor desempenho para esta finalidade.

**Palavras-chaves:** Automatização. Filtro de máximos globais. Censo florestal. RPAS. Sensoriamento Remoto 3D.

## ABSTRACT

The goal of this research was the creation of an algorithm for automatic detection of trees from point cloud generated by RPAS's optical images. The algorithm, called DAA (*Detecção Automática de Árvores*), whose operation is based on the methodology of global maxima filter, was applied in two types of *Pinus taeda*'s forests plantings: young planting, 2 years of age and adult planting, of 11 years old. To analyze the potential for DAA, it was first applied in a pre-processed 3D spot cloud of young, 2-year-old planting. The result obtained was satisfactory, with 91% of the seedlings detected automatically by the algorithm. When applied to adult planting, the DAA was compared to another algorithm of automatic tree detection, the ITD (Individual Tree Detection), whose principle of operation is based on the method of local maxima filter, the most used for this type of activity. When comparing the two algorithms with the counting methods in the field and counting by photointerpretation of orthophoto, the DAA presented better results, with 93% of correctly detected trees when compared to orthophoto counts and 89% in relation to the forest census. On the other hand, the ITD presented values of 71% of hits in relation to orthophoto and 74% in relation to the forest census. Therefore, the ITD algorithm underestimated the total number of trees in the adult field, and DAA obtained better performance for this purpose.

**Key-words:** Automation. 3D Remote Sensing. Forest census. Global maxima filter. RPAS.

## LISTA DE FIGURAS

FIGURA 1: RELAÇÃO DE ARTIGOS PUBLICADOS SOBRE O TEMA DETECÇÃO AUTOMÁTICA DE ÁRVORES POR SENSORIAMENTO REMOTO. ....	17
FIGURA 2 - ARQUITETURA DO MÉTODO DE RECONSTRUÇÃO 3D DE OBJETOS PRESENTES NA SUPERFÍCIE A PARTIR DE IMAGENS ÓPTICAS.....	22
FIGURA 3 - DEMONSTRAÇÃO DE PONTOS CHAVE EM DIFERENTES IMAGENS DE UM MESMO OBJETO. ....	22
FIGURA 4 - REPRESENTAÇÃO DA GEOMETRIA EPIPOLAR ENTRE DUAS IMAGENS .....	25
FIGURA 5 - REPRESENTAÇÃO DA OBTENÇÃO DA MATRIZ FUNDAMENTAL A PARTIR DA GEOMETRIA EPIPOLAR.....	26
FIGURA 6 - EXEMPLO DA VARIAÇÃO DO NÚMERO TOTAL DE ÁRVORES DETECTADAS AO APLICAR O FILTRO DE MÁXIMAS LOCAIS EM IMAGEM IKONOS. ....	29
FIGURA 7 - REPRESENTAÇÃO DOS FORMATOS TRABALHADOS DA NUVEM DE PONTOS 3D	30
FIGURA 8 - FILTRO DE MÁXIMA LOCAL APLICADO À SUPERFÍCIE DO DOSSEL FLORESTAL..	31
FIGURA 9 - VISUALIZAÇÃO BIDIMENSIONAL E TRIDIMENSIONAL DE UMA IMAGEM DE UMA ÁREA DE FLORESTA EM RELAÇÃO AOS VALORES DE REFLECTÂNCIA PRESENTES NOS PÍXEIS DA IMAGEM. ....	32
FIGURA 10 - DETECÇÃO DE ÁRVORES ATRAVÉS DO FILTRO DE MÁXIMA LOCAL APLICADO À SUPERFÍCIE DO DOSSEL FLORESTAL.....	33
FIGURA 11 - DISTÂNCIA ENTRE O ÁPICE DE ÁRVORES COM COPAS ISOLADAS (A) E CONTÍGUAS (B). ....	34
FIGURA 12 - DISTÂNCIA ENTRE PONTOS A, B, C, D E REFERENTE A DUAS ÁRVORES .....	35
FIGURA 13 - ORTOFOTOS DAS ÁREAS DE ESTUDO. A) PLANTIO JOVEM DE <i>PINUS</i> SPP.; B) PLANTIO ADULTO RECÉM DESBASTADO DE <i>PINUS</i> SPP. ....	36
FIGURA 14 - IMAGEM EM PERSPECTIVA DO TALHÃO ADULTO UTILIZADO PARA IMPLEMENTAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES. ....	38
FIGURA 15 - DRONE QUADCOPTER DJI PHANTOM 4 PRO UTILIZADO NA OBTENÇÃO DAS IMAGENS.....	39
FIGURA 16 - FLUXOGRAMA DE REPRESENTAÇÃO DAS ETAPAS DO PROCEDIMENTO ADOTADO PARA OBTENÇÃO DA NUVEM DE PONTOS APTA PARA PASSAR PELA DETECÇÃO AUTOMÁTICA DE ÁRVORES PELO ALGORITMO.....	40
FIGURA 13 - REPRESENTAÇÃO DO FUNCIONAMENTO DO SISTEMA <i>STRUCTURE FROM MOTION</i> . ....	41
FIGURA 14 - NUVENS DE PONTOS 3D OBTIDAS A PARTIR DE TÉCNICAS DE VISÃO COMPUTACIONAL EM IMAGENS ÓPTICAS AÉREAS. ....	41
FIGURA 19 - A) NUVEM DE PONTOS OBTIDA A PARTIR DE FOTOGRAFIAS AÉREAS COM POUCA ILUMINAÇÃO SOLAR OU ALTA INCIDÊNCIA DE SOMBRAS; B) NUVEM DE PONTOS 3D OBTIDA A PARTIR DE FOTOGRAFIAS AÉREAS COM ALTA LUMINOSIDADE E POUCA SOMBRA. ....	43

FIGURA 16 - REPRESENTAÇÃO DO FUNCIONAMENTO DO ALGORITMO <i>CLOTH SIMULATION FILTERING</i> .....	45
FIGURA 21 - NORMALIZAÇÃO DA NUVEM DE PONTOS DO TALHÃO ADULTO.....	47
FIGURA 22 - NUVENS DE PONTOS 3D PRÉ-PROCESSADAS UTILIZADAS COMO ARQUIVO DE ENTRADA PARA A APLICAÇÃO DO ALGORITMO. ....	48
FIGURA 23 - FLUXOGRAMA DAS ETAPAS DE COLETA DE IMAGENS, PRÉ-PROCESSAMENTO, AJUSTE DE PARÂMETROS E DETECÇÃO DAS ÁRVORES NA NUVEM DE PONTOS DO TALHÃO OBTIDA DE IMAGENS ÓPTICAS DE RPAS.....	49
FIGURA 24 - ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES EM NUVEM DE PONTOS 3D. ....	50
FIGURA 21 - REPRESENTAÇÃO DA OBTENÇÃO DO PARÂMETRO $H_{DOSSEL}$ NA NUVEM DE PONTOS DO PLANTIO ADULTO.....	51
FIGURA 26 - DISPOSIÇÃO DAS UNIDADES AMOSTRAIS UTILIZADAS PARA AJUSTE DE PARÂMETROS DO DAA .....	60
FIGURA 27 - FLUXOGRAMA DAS ETAPAS DE COLETA DE IMAGENS, PRÉ-PROCESSAMENTO, AJUSTE DE PARÂMETROS E DETECÇÃO DAS ÁRVORES NA NUVEM DE PONTOS DO TALHÃO OBTIDA DE IMAGENS ÓPTICAS DE RPAS.....	61
FIGURA 28 - RESULTADO DA APLICAÇÃO DO ALGORITMO DAA EM UMA UNIDADE AMOSTRAL DE PLANTIO JOVEM DE <i>PINUS SPP</i> . ....	64
FIGURA 29 - RESULTADO DA SEGMENTAÇÃO AUTOMÁTICA PELO ALGORITMO DAA EM PLANTIO JOVEM DE <i>PINUS TAEDA</i> . ....	65
FIGURA 30 - IMAGEM EM PERSPECTIVA DO TALHÃO ADULTO UTILIZADO PARA IMPLEMENTAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES. ....	74
FIGURA 31 - A) NUVEM DE PONTOS 3D DO PLANTIO ADULTO ANTES DO PRÉ-PROCESSAMENTO; B) MODELO DIGITAL DO DOSSEL NO FORMATO RASTER.....	75
FIGURA 32 - ILUSTRAÇÃO DE COMO É OBTIDO A VARIÁVEL $H_{DOSSEL}$ PARA AJUSTE DE PARÂMETRO DO ALGORITMO DAA .....	75
FIGURA 33 - REPRESENTAÇÃO DA VARIAÇÃO ENTRE A POSIÇÃO DA BASE DA ÁRVORE E O ÁPICE DA COPA. ....	76
FIGURA 34 - DETECÇÃO AUTOMÁTICA DAS ÁRVORES A PARTIR DO ALGORITMO ITD E CONTAGEM VISUAL PELA FOTOINTERPRETAÇÃO DA ORTOFOTO. ....	78
FIGURA 35 - RESULTADO DA DETECÇÃO AUTOMÁTICA DE ÁRVORES PELO ALGORITMO ITD EM TODOS OS BLOCOS DO TALHÃO ESTUDADO DE 11 ANOS.....	79
FIGURA 36 - PROCESSO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES EM NUVENS DE PONTOS DE IMAGENS ÓPTICAS NAS AMOSTRAS DE TREINAMENTO.....	81
FIGURA 37 - RESULTADO DA DETECÇÃO AUTOMÁTICA DE ÁRVORES PELO ALGORITMO DAA EM TODOS OS BLOCOS DO TALHÃO ESTUDADO DE 11 ANOS.....	82
FIGURA 38 - RESULTADO DA CONTAGEM DE ÁRVORES EM PLANTIO FLORESTAL HOMOGÊNEO DE <i>PINUS SPP</i> DE 11 ANOS. ATRAVÉS DE QUATRO MÉTODOS DISTINTOS: CENSO FLORESTAL, FOTOINTERPRETAÇÃO, ALGORITMO ITD E ALGORITMO DAA.....	83

FIGURA 39 - DETECÇÃO AUTOMÁTICA DAS ÁRVORES A PARTIR DOS MÉTODOS DE FOTOINTERPRETAÇÃO, ALGORITMO ITD E DAA. ....	85
FIGURA 40 - A) DETALHAMENTO DOS CASOS DE FALSOS NEGATIVOS (ERROS DE OMISSÃO) COMETIDOS PELO ALGORITMO EM ÁRVORES SUPRIMIDAS; B) DETALHAMENTO DOS CASOS DE FALSOS POSITIVOS (ERROS DE COMISSÃO) COMETIDOS PELO ALGORITMO EM ÁRVORES DOMINANTES COM COPAS EXTENSAS E PROLONGADAS. ....	86

## LISTA DE TABELAS

TABELA 1 - CARACTERÍSTICAS DO TALHÃO JOVEM SELECIONADO PARA APLICAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DE NUVEM DE PONTOS DE IMAGENS ÓPTICAS DE RPAS. ....	37
TABELA 2 - CARACTERÍSTICAS DO TALHÃO ADULTO SELECIONADO PARA APLICAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DE NUVEM DE PONTOS 3D DE IMAGENS ÓPTICAS DE RPAS. ....	37
TABELA 3 - RESULTADO DA DETECÇÃO AUTOMÁTICA DE ÁRVORES NAS UNIDADES AMOSTRAIS DO PLANTIO JOVEM DE 2 ANOS. ....	63
TABELA 4 - RESULTADO DA APLICAÇÃO DO DAA EM PLANTIOS JOVENS DE <i>PINUS SPP.</i> ....	64
TABELA 5 - CARACTERÍSTICAS DOS DOIS ALGORITMOS DE DETECÇÃO AUTOMÁTICA DE ÁRVORES. ....	73
TABELA 6 - RESULTADO DA APLICAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES NAS AMOSTRAS DE TREINAMENTO DO PLANTIO ADULTO DE <i>PINUS SPP.</i> DE 11 ANOS. ....	81

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>15</b>
1.1 Objetivo Geral .....	16
1.2 Objetivos específicos .....	16
1.3 RELEVÂNCIA CIENTÍFICA E JUSTIFICATIVA .....	17
1.4 ESTRUTURA DA DISSERTAÇÃO .....	18
1.5 REVISÃO DE LITERATURA.....	20
1.5.1 <i>Remotely Piloted Aircraft Systems</i> – RPAS .....	20
1.5.2 Geração de nuvens de pontos 3D a partir de dados ópticos .....	22
1.5.3 Detecção automática de árvores .....	28
1.5.4 Filtro de Máximos Locais .....	31
1.5.5 Filtro de Máximos Globais .....	33
1.6 MATERIAL E MÉTODOS.....	36
1.6.1 Áreas de estudo.....	36
1.6.2 Coleta de dados.....	38
1.6.2.1 Levantamento da quantidade de indivíduos .....	38
1.6.2.2 Levantamento das fotografias aéreas.....	38
1.6.3 Pré-processamento da nuvem de pontos 3D.....	40
1.6.3.1 Obtenção das nuvens de pontos 3D.....	40
1.6.3.2 Filtragem das nuvens .....	44
1.6.3.3 Reamostragem das nuvens de pontos 3D.....	44
1.6.3.4 Modelo Digital do Terreno .....	45
1.6.3.5 Normalização das nuvens de pontos 3D .....	47
1.6.4 Algoritmo de Detecção Automática de Árvores (DAA).....	48
<b>REFERÊNCIAS.....</b>	<b>53</b>
<b>2 DETECÇÃO AUTOMÁTICA DE ÁRVORES EM UM PLANTIO JOVEM DE <i>Pinus</i> spp. A PARTIR DE NUVENS DE PONTOS 3D OBTIDAS DE IMAGENS ÓPTICAS DE RPAS (<i>REMOTELY PILOTED AIRCRAFT SYSTEM</i>).....</b>	<b>56</b>
2.1 INTRODUÇÃO .....	58
2.2 MÉTODOS.....	59
2.2.1 Ajuste dos parâmetros do DAA.....	59
2.2.2 Avaliação do algoritmo no plantio jovem.....	61
2.3 RESULTADOS E DISCUSSÃO .....	63
2.3.1 Desempenho do DAA nas amostras de treinamento .....	63
2.3.2 Validação do algoritmo de detecção DAA.....	64
2.4 CONCLUSÃO .....	67
<b>REFERÊNCIAS.....</b>	<b>68</b>
<b>3 COMPARAÇÃO ENTRE DOIS MÉTODOS DE DETECÇÃO AUTOMÁTICA DE ÁRVORES: A PARTIR DE NUVENS DE PONTOS 3D E MODELO DIGITAL DE DOSSEL EM FORMATO RASTER .....</b>	<b>70</b>
3.1 INTRODUÇÃO.....	72
3.2 MÉTODOS.....	73
3.2.1 Algoritmo ITD (Individual Tree Detection) .....	74
3.2.2 Ajuste dos parâmetros do DAA.....	75
3.2.3 Avaliação de desempenho dos algoritmos .....	77



3.3 RESULTADOS E DISCUSSÃO .....	78
3.3.1 Detecção de árvores a partir do algoritmo ITD .....	78
3.3.2 Detecção de árvores a partir do algoritmo DAA.....	80
3.3.3 Comparação entre métodos .....	82
3.4 CONCLUSÃO .....	87
<b>REFERÊNCIAS.....</b>	<b>88</b>
<b>4 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES.....</b>	<b>90</b>
<b>REFERÊNCIAS.....</b>	<b>92</b>
<b>ANEXO 1.....</b>	<b>98</b>
<b>ANEXO 2.....</b>	<b>99</b>

## 1 INTRODUÇÃO

O uso de informações tridimensionais e multiespectrais no Sensoriamento Remoto representa um grande avanço no estudo da vegetação, principalmente no que diz respeito ao conhecimento da estrutura do dossel vegetal (DANDOIS et al., 2017) e contagem de indivíduos. Atualmente, a contagem de mudas e árvores em plantios florestais é realizada principalmente por meio de duas metodologias: 1) levantamento de campo; e 2) contagem manual por fotointerpretação de ortofoto de imagens aéreas de RPAS (*Remotely Piloted Aircraft*). Poucos métodos automatizados para efetuar esta atividade são utilizados, ou devido à alta complexidade exigida para o manuseio de tais programas computacionais ou pela baixa acurácia obtida, que não atinge as demandas exigidas pelas empresas florestais.

A maioria dos métodos automáticos de detecção de árvores usam imagens multiespectrais de satélites, ortofotos ou modelo digital do dossel no formato raster, extraídos muitas vezes de fotografias aéreas estereoscópicas de RPAS como dado de entrada (GEBRESLASIE et al., 2011; MOHAN et al., 2017). Alguns deles mostram a grande viabilidade para a utilização de nuvens de pontos 3D geradas a partir dessas imagens ópticas para possibilitar melhorias na detecção automática de árvores (LI et al., 2012; WALLACE; LUCIEER; WATSON, 2014).

Diante dessa realidade, o desenvolvimento de métodos para detecção automática de árvores a partir de nuvens de pontos 3D de imagens ópticas tem potencial para redução de custos de inventários florestais e de tempo de contabilização de árvores em campo e de interpretação visual de ortofoto. Alguns autores afirmam que estas nuvens possuem características de representação 3D semelhante às obtidas com nuvens de pontos 3D de sistemas laser aerotransportado quando aplicado em área florestal (DANDOIS; ELLIS, 2013; FRITZ; KATTENBORN; KOCH, 2013).

O conhecimento acerca do número de indivíduos existentes em uma floresta é de enorme interesse para realização do planejamento. Nesse contexto, este trabalho tem como objetivo apresentar um algoritmo computacional para detecção de árvores em plantios florestais de *Pinus* spp. utilizando nuvens de pontos 3D obtidas de imagens ópticas de RPAS.

## 1.1 OBJETIVO GERAL

O objetivo geral consiste em propor um algoritmo computacional, baseado no método de filtro de máximos globais, chamado DAA (Detecção Automática de Árvores) visando obter o número total de árvores jovens e adultas em povoamentos florestais homogêneos a partir de nuvens de pontos 3D geradas de imagens ópticas de RPAS (*Remotely Piloted Aircraft System*).


## 1.2 OBJETIVOS ESPECÍFICOS

- Analisar o comportamento tridimensional das copas e do dossel florestal e estabelecer atributos para formular um algoritmo para detecção automática de árvores jovens e adultas de *Pinus spp.*;
- Avaliar o desempenho do algoritmo proposto em plantios de 2 anos e de 11 anos e verificar a completude dos dados;
- Comparar o algoritmo de detecção de árvores (DAA) proposto com o algoritmo ITD (*Individual Tree Detection*), e comparar o desempenho de ambos com os métodos de contagem visual (por interpretação de ortofoto) e censo florestal em campo.

### 1.3 RELEVÂNCIA CIENTÍFICA E JUSTIFICATIVA

Como mencionado anteriormente, a contagem de árvores realizada atualmente é, na maioria das vezes, realizada por meio de interpretação de ortofoto do povoamento florestal, ou por contagem do número de árvores em campo, sendo atividades bastante onerosas e de alto custo. A busca por métodos computacionais que executem esta tarefa existe desde a década de 1990 e vem crescendo ao longo dos anos. Fato comprovado pelo crescente número de publicações abordando esse tema. Através de pesquisas pelos termos “*Tree Detection*”, “*Tree Segmantation*” e “*point cloud*”, no site *web of Science*, foi verificado que este assunto foi abordado em 211 trabalhos publicados, sendo a maioria das referências publicadas a partir de do ano de 2006 (FIGURA 1).

FIGURA 1: RELAÇÃO DE ARTIGOS PUBLICADOS SOBRE O TEMA DETECÇÃO AUTOMÁTICA DE ÁRVORES POR SENSORIAMENTO REMOTO.



A maioria dos métodos desenvolvidos para detecção automática de árvores consiste em algoritmos de grande complexidade, que funciona em produtos derivados de LASER Scanner, o que incide em alto custo para geração e obtenção dos dados. O desenvolvimento de um algoritmo para detecção automática de árvores a partir de nuvens de pontos 3D de imagens ópticas de RPAS justifica-se por: RPAS consistir em um equipamento de baixo custo e fácil manuseio, bem como por oferecer flexibilidade temporal para aquisição de informações; possibilidade de obtenção de nuvens de pontos 3D densas e de alta resolução espacial.

Outro fator que justifica a aplicação de um algoritmo em nuvens de pontos 3D de imagens ópticas de RPAS neste trabalho é que a maioria dos métodos existentes para detecção automática de árvores utiliza derivados das nuvens de pontos 3D, como modelo digital de superfície ou mesmo as ortofotos geradas a partir das imagens aéreas, o que muitas vezes reduz o desempenho obtido pelos algoritmos criados. Trabalhar com a nuvem de pontos 3D pode aumentar a acurácia dos algoritmos, por oferecer ricas informações sobre a estrutura tridimensional do povoamento florestal.

Este trabalho tem como principal contribuição o desenvolvimento de uma abordagem de algoritmo de detecção automática de árvores baseado na aplicação de filtro de máximos globais na nuvem de pontos 3D obtida de dados ópticos. O filtro de máximos globais é um método pouco utilizado na literatura para realização de tal função, porém é um dos que apresenta resultados mais robustos, quando aplicado em nuvens de pontos 3D de LASER.

#### 1.4 ESTRUTURA DA DISSERTAÇÃO

O método para detecção de árvores em plantios florestais homogêneos aqui apresentado ocorre a partir da criação e implementação de um algoritmo, denominado DAA (Detecção Automática de Árvores). Este trabalho está estruturado da seguinte forma:

- Capítulo 1: Aspectos gerais da pesquisa – neste capítulo são apresentados: objetivos gerais e específicos; revisão de literatura, na qual abrange tópicos geração de nuvens de pontos 3D a partir de imagens ópticas, uso civil de RPAS e o estado da arte dos algoritmos desenvolvidos para detecção automática de árvores a partir de sensores remotos; materiais e métodos referentes a dissertação, no qual são apresentadas áreas de estudo, metodologia de coleta de dados e todas as etapas de obtenção e pré-processamento das nuvens de pontos 3D a partir de imagens ópticas de RPAS; e, finalmente, é apresentado o algoritmo DAA (Detecção Automática de Árvores), e sua lógica de funcionamento na nuvem de pontos 3D.

- Capítulo 2: Detecção automática de árvores em um plantio jovem de *Pinus* spp. a partir de nuvens de pontos 3D de imagens ópticas de RPAS (*Remotely Piloted Aircraft System*) - apresenta o funcionamento do algoritmo DAA aplicado na detecção automática de árvores em um plantio jovem de 2 anos de *Pinus* spp., cujas

copas das árvores ainda não estão entrelaçadas. Apresenta os erros de omissão e comissão e avaliação dos resultados obtidos pelo algoritmo DAA em relação ao número de árvores contabilizadas manualmente pela ortofoto.

- Capítulo 3: Comparação entre dois métodos de detecção automática de árvores a partir de nuvens de pontos 3D e modelo digital do dossel em formato raster - o algoritmo DAA e o algoritmo ITD (*Individual Tree Detection*), implementado no *software* livre R, são aplicados em um povoamento adulto de *Pinus* spp. de 11 anos recém desbastado. Os algoritmos testados possuem metodologias de funcionamento diferentes entre si: o DAA tem como *input* uma nuvem de pontos pré-processada no formato x, y, z, enquanto o ITD tem como input o formato rasterizado desta nuvem de pontos 3D pré-processada, utilizada pelo DAA. A fim de analisar a acurácia dos algoritmos em relação a outros métodos, os resultados também foram confrontados com um censo florestal da área e por contagem visual de árvores realizada a partir de fotointerpretação da ortofoto do plantio.

- Capítulo 4: Considerações finais e recomendações – neste capítulo foi realizada verificação dos resultados, atendimento aos objetivos propostos, conclusões e recomendações para a utilização de imagens óticas de RPAS para geração de nuvens de pontos 3D para detecção automática de árvores em povoamentos florestais.

## 1.5 REVISÃO DE LITERATURA

### 1.5.1 *Remotely Piloted Aircraft Systems* – RPAS

RPAS são plataformas aéreas de baixo custo operadas do solo, podendo conter ou não sensores de captura de imagens, com potencial para rápido monitoramento com baixo custo de fenômenos ambientais, oferecendo soluções espacial e temporal apropriadas para estudos ecológicos (MULAC, 2011; ANDERSON; GASTON, 2013; GETZIN; NUSKE; WIEGAND, 2014; SIEBERT; TEIZER, 2014; SOTIER, 2014). Estes aparelhos possuem diversas denominações na literatura, como UAV (*Unmanned Aerial Vehicles*), robôres aéreos, Veículos Aéreos Não Tripulados (VANT), ou simplesmente Drone (COLOMINA; MOLINA, 2014).

Com uso restrito para fins militares desde a segunda guerra mundial, os RPAS foram inseridos no meio civil nas últimas décadas, nas quais passou por rápidas evoluções de acordo com a necessidade do mercado, variando em diversos tipos, tamanhos e modelos (ANDERSON; GASTON, 2013; NEX; REMONDINO, 2014). O uso civil dos RPAS tem possibilitado crescimento de pesquisas em diversas áreas, como agricultura de precisão, ecologia, construções etc. (COLOMINA; MOLINA, 2014; SHAHBAZI et al., 2015; XIANG; TIAN, 2011). Muitos trabalhos apresentam seu uso no setor florestal, principalmente em monitoramento de incêndios, obtenção de dados de biodiversidade e variáveis dendrométricas (PULITI et al., 2015; SHAHBAZI et al., 2015; TANG; SHAO, 2015).

Recentes estudos ao utilizar RPAS como ferramenta para obtenção de Modelo Digital de Superfície (MDS), geração de ortofotos, no âmbito da Fotogrametria e Sensoriamento Remoto vêm obtendo bastante êxito (FRITZ; KATTENBORN; KOCH, 2013a; HARWIN; LUCIEER; OSBORN, 2015). Nex & Remondino (2014) apontam o uso desta plataforma como uma alternativa muito importante para estudar e explorar o ambiente, em particular aqueles de difícil acesso ou os que necessitam de resultados mais rápidos. Para maximizar o potencial da tecnologia RPAS para aplicações ambientais e na agricultura, é essencial a utilização de técnicas eficientes, automáticas e com acurácia elevada para tratamento de grande quantidade de imagens geradas por este instrumento (TURNER; LUCIEER; WATSON, 2012).



Na área florestal, especificamente, os RPAS possuem a vantagem de captura de informações de árvores, de forma a servir de auxílio nos inventários florestais e permitir a redução de parcelas de campo a serem levantadas, atendendo às necessidades das empresas florestais e constituindo de um grande potencial para gerenciamento e previsão de produtividade florestais (JIANG et al., 2017).

Kattenborn et al. (2014) ao utilizarem imagens de VANT para identificação automática de palmeiras em duas alturas de sobrevoo diferentes, chegaram a bons resultados. Com sobrevoo a 100 metros de altura, chegou a 86,1% de individualização automática das palmeiras, enquanto que a 70 metros chegou a 68,8% de individualização. Os autores também chegaram à conclusão de que a escala das imagens (afetada pela altura do voo) é inversamente proporcional ao erro de individualização dos indivíduos.

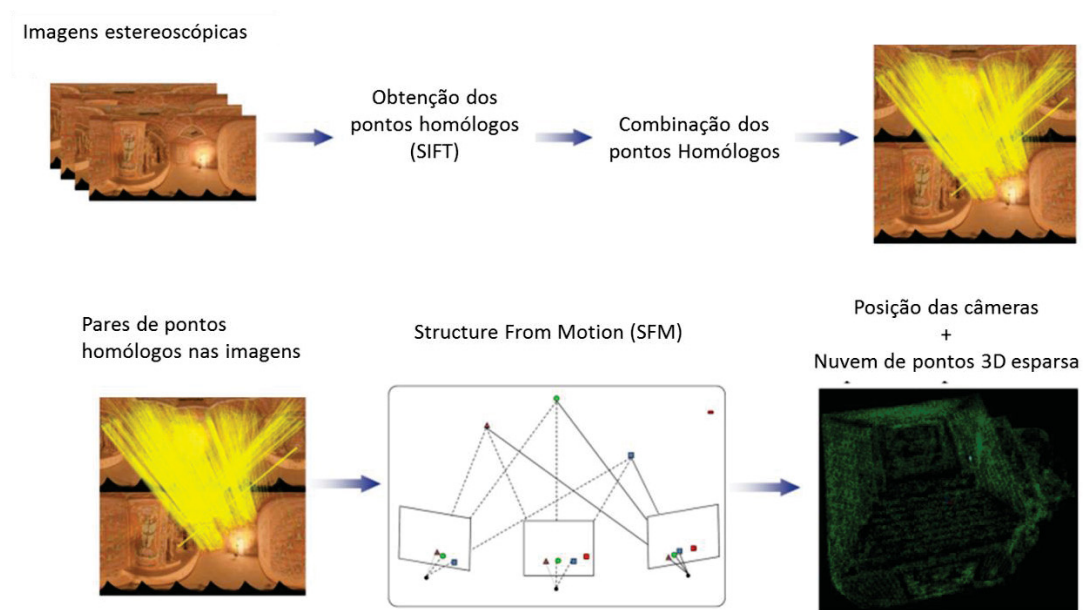
A partir das imagens de alta resolução espacial, facilitado pelas plataformas VANTs, é possível gerar densas nuvens de pontos 3D e modelo digital de superfície (MDS) (HARWIN et al., 2015), usando técnicas de Fotogrametria digital. A densidade da nuvem de pontos é diretamente proporcional ao número de feições combinadas, textura de superfícies, oclusões e mudanças de iluminação (HARWIN & LUCIEER, 2012a).

Segundo estudo realizado por Dandois e Ellis (2013), a nuvem de pontos 3D obtida de fotografias aéreas apresentou densidade de pontos superior à gerada por *Sistemas Laser* aerotransportado. Ainda segundo os autores, a nuvem de pontos geradas por imagens apresentou coeficiente de determinação ( $R^2$ ) semelhante aos dados obtidos por LiDAR para estimativa de altura de dossel florestal.

### 1.5.2 Geração de nuvens de pontos 3D a partir de dados ópticos

A obtenção de nuvens de pontos 3D a partir de imagens 2D de um mesmo objeto ocorre por meio de técnicas de Fotogrametria digital que são, atualmente, muito empregadas em visão computacional. A arquitetura do método de reconstrução 3D de objetos está apresentada na FIGURA 2.


FIGURA 2 - ARQUITETURA DO MÉTODO DE RECONSTRUÇÃO 3D DE OBJETOS PRESENTES NA SUPERFÍCIE A PARTIR DE IMAGENS ÓPTICAS.



FONTE: GAVA, 2011.

A obtenção da nuvem de pontos 3D a partir de imagens ópticas ocorre, primeiramente, com a extração de pontos chave presentes no espaço imagem, dos quais consistem em pixels correspondentes a um mesmo objeto na imagem (FIGURA 3).

FIGURA 3 - DEMONSTRAÇÃO DE PONTOS CHAVE EM DIFERENTES IMAGENS DE UM MESMO OBJETO.



FONTE: GAVA, 2011.

Na FIGURA 3 estão apresentadas duas imagens sob perspectivas diferentes de um mesmo objeto. Os pontos chave (pontos em vermelho) são detectados automaticamente em diversas imagens, mesmo com diferenças de escala, rotação e pontos de vistas. Isto é feito através do algoritmo *Scale Invariant Feature Transform* (SIFT), proposto por Lowe (2004). O SIFT é invariante a escala, rotação e mudança de ponto de vista das imagens.

Basicamente, o algoritmo SIFT possui três etapas: 1) A detecção de pontos chave; 2) A geração de descritores locais; e 3) O estabelecimento de correspondências. Primeiro, o algoritmo procura pontos invariantes à mudança de escala na imagem utilizando uma função Gaussiana (espaço-escala). O espaço-escala é definido como uma convolução da imagem  $I(u, v)$  com um operador Gaussiano  $G(u, v, \vartheta)$ , como segue (LOWE, 2004):

$$L(u, v, \vartheta) = G(u, v, \vartheta) \otimes I(u, v)$$

Em que:

$L$ : imagem suavizada;

$u$  e  $v$ : coordenadas do pixel na imagem;

$\vartheta$ : variação de escala em  $G$  (parâmetro que define o fator de suavização da imagem  $I$ );

$$G(u, v, \vartheta) = \frac{1}{2\pi\vartheta^2} e^{-\frac{(u^2+v^2)}{2\vartheta^2}}.$$

Em seguida, são realizados cálculos de Diferença de Gaussianas (*Difference of Gaussians - DoG*) para cada oitava no espaço-escala. Esta função é separada por uma escala constante ( $k$ ) e definida pela diferença de  $L$  em escalas próximas (ver FIGURA 4), como segue (LOWE, 2004):

$$DoG(u, v, \vartheta) = L(u, v, k \cdot \vartheta) - L(u, v, \vartheta)$$

A equação acima proporciona um valor aproximado para a escala normalizada Laplaciana-Gaussiana ( $\vartheta^2 \nabla^2 G$ ), como segue (LOWE, 2004):

$$\vartheta^2 \nabla^2 G = \frac{\partial G}{\partial \vartheta} \approx \frac{L(u, v, k \cdot \vartheta) - L(u, v, \vartheta)}{k \cdot \vartheta - \vartheta}$$

e, por conseguinte:

$$L(u, v, k \cdot \vartheta) - L(u, v, \vartheta) \approx (k - 1) \cdot \vartheta^2 \nabla^2 G$$

O fator  $\vartheta^2$  faz com que a escala seja invariante. Na sequência, a localização dos pontos visuais é feita por aproximações de  $\vartheta^2 \nabla^2 G$ . Conforme mostrado por Lowe (2004), o fator remanescente  $(k - 1)$  não influencia na posição do pixel detectado.

Na sequência, os valores de máximo ou mínimo locais são detectados para cada *DoG* obtido comparando todos os pixels de borda na imagem *DoG* com seus vizinhos do espaço-escala corrente. Posteriormente, os pontos visuais são localizados e se não forem estáveis, devem ser descartados. A localização exata dos pontos visuais é determinada através do ajustamento de uma função quadrática 3D (detalhes ver BROW E LOWE, 2002).


Para cada ponto chave é atribuída uma orientação canônica fazendo com que os descritores sejam invariantes à rotação (LOWE, 1999). Então, para cada ponto chave e seus pixels vizinhos é gerado um histograma de orientações. Os pixels vizinhos são adicionados ao histograma com pesos correspondentes aos valores de magnitude e também aos valores determinados por uma função Gaussiana. O histograma possui 36 regiões, cobrindo todas as orientações

possíveis (intervalos de  $10^\circ$ ). O resultado esperado é um conjunto de descritores que podem ser usados no estabelecimento automático de correspondências entre pontos. Finalmente, a correspondência entre os pontos de interesse pode ser efetuada por intermédio do cálculo de alguma medida de similaridade que descreve a relação entre os descritores em uma dada vizinhança. Finalmente, as correspondências são obtidas usando o método de *Best-Bin-First* (BBF), proposto por Beis e Lowe (1997).

A partir da detecção dos pontos chave existente entre as múltiplas imagens, o passo seguinte consiste em obter a correspondência entre eles. Isto é feito através de uma técnica conhecida como geometria epipolar. A geometria epipolar representa a geometria projetada intrínseca entre duas imagens e depende apenas dos parâmetros internos da câmera e sua orientação relativa, sendo independente da estrutura da cena (HARTLEY; ZISSERMAN, 2004).

Ao considerar um ponto  $X$  em uma posição tridimensional no espaço objeto, capturado em duas cenas, nas quais na primeira o ponto aparece como  $x$  e na segunda cena como  $x'$ . Como mostrado na FIGURA 4, os pontos  $X$ ,  $x$ ,  $x'$  e o centro perspectivo da câmera são coplanares. Tal plano é chamado de plano epipolar ( $\pi$ ).

FIGURA 4 - REPRESENTAÇÃO DA GEOMETRIA EPIPOLAR ENTRE DUAS IMAGENS




A) PLANO EPIPOLAR ENTRE IMAGENS COM PONTOS CORRESPONDENTES CONHECIDOS NAS DUAS IMAGENS. B) GEOMETRIA EPIPOLAR QUANDO UM PONTO DE CORRESPONDÊNCIA  $X$  É OBTIDO EM APENAS UMA IMAGEM, OBTENÇÃO DA LINHA EPIPOLAR E EPIPOLE PARA ESTIMATIVA DA LOCALIZAÇÃO DO PONTO  $X'$  NA SEGUNDA IMAGEM.

Fonte: Hartley; Zisserman (2004).

Na FIGURA 4 a projeção do ponto  $X$  para as imagens através do plano epipolar, fornece informação do centro perspectivo de cada uma das imagens.

Mesmo que apenas o ponto  $x$  seja obtido, através do plano epipolar é possível obter  $x'$  pelo raio de projeção que este forma com a linha epipolar de  $x$  e o epipole de  $C$ . Esta relação entre os elementos da geometria epipolar pode ser algebricamente representada pela Matriz Fundamental (HARTLEY; ZISSERMAN, 2004), como mostra a FIGURA 5.

FIGURA 5 - REPRESENTAÇÃO DA OBTENÇÃO DA MATRIZ FUNDAMENTAL A PARTIR DA GEOMETRIA EPIPOLAR.



FONTE: HARTLEY; ZISSERMAN, 2004

Basicamente, a Matriz Fundamental relaciona os pares de pontos correspondentes  $x_i$  e  $x'_i$ , sendo  $x$  um ponto chave qualquer pertencente à imagem de referência e  $x'$  o possível ponto correspondente na outra imagem, de forma que a equação a seguir seja satisfeita (ZHANG, 1998):

$$x_i'^T \cdot F \cdot x_i = 0$$

Sendo  $F$  a Matriz Fundamental de ordem 3 com seu determinante nulo e que pode ser calculada da seguinte forma:

$$x_i'^T \cdot F \cdot x_i = \begin{bmatrix} x'_i & y'_i & 1 \end{bmatrix} \begin{bmatrix} cf_{11} & cf_{12} & cf_{13} \\ cf_{21} & cf_{22} & cf_{23} \\ cf_{31} & cf_{32} & cf_{33} \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} = 0$$

Em que:

$cf_{11}, \dots, cf_{33}$ : os coeficientes de  $F$ .

Fazendo as devidas multiplicações matemáticas e considerando  $cf = (cf_{11}, cf_{12}, cf_{13}, cf_{21}, cf_{22}, cf_{23}, cf_{31}, cf_{32}, cf_{33})$ , a equação acima pode ser reescrita da seguinte, a saber:

$$cf(x'_i x_i, x'_i y_i, x'_i y'_i x_i, y'_i y_i, y'_i x_i, y'_i, x_i, y_i, 1) = 0$$

Assim, para solucionar a equação acima é necessário usar técnicas de otimização matemática, tais como, o SVD (*Singular Value Decomposition*), MMQ (Método dos Mínimos Quadrados) e etc.

Desde que os coeficientes da Matriz  $F$  sejam determinados e um conjunto de pares de pontos chaves são obtidos as coordenadas 3D de pontos na superfície podem ser determinadas usando a seguinte expressão, a saber (Hartley *et al.*, 1992):

$$h = Fp_i$$

Em que:

$$h = \lambda(x_i, x'_i, 1)^T, p_i = [x_i, y_i, z_i, 1]^T \text{ e } \lambda \text{ um fator de escala desconhecido.}$$

Considerando  $f_i^T$  a  $i$ -ésima linha da matriz  $F$  e fazendo algumas manipulações matemáticas,  $h = Fp_i$  pode ser escrita da seguinte forma, a saber:

$$x_i f_3^T p_i = f_1^T p_i$$

$$x'_i f_3^T p_i = f_2^T p_i$$

Assumindo  $p_i = [x_i, y_i, z_i, 1]^T$  tem-se um sistema do tipo  $Ap_i = \mathbf{b}$ , sendo  $A$  uma matriz de dimensão  $4 \times 3$ ,  $p_i$  um vetor de dimensão  $3 \times 1$  e  $\mathbf{b}$  um vetor de dimensão  $4 \times 1$ . Dessa forma, o sistema  $Ap_i = \mathbf{b}$  pode ser solucionado por SVD ou pelo MMQ, resultando em coordenadas 3D  $(x_i, y_i, z_i)$  do ponto  $p_i$ . Isto deve ser feito para todos os pontos no par de imagens.



### 1.5.3 Detecção automática de árvores


Existem diversos métodos propostos para detecção automática de árvores a partir de dados de sensores remotos. Esses métodos podem ser agrupados de acordo com o tipos de dados de entrada, como imagens multiespectrais ou nuvens de pontos 3D (JIANG et al., 2017).

Na abordagem de imagens multiespectrais, alguns métodos foram desenvolvidos ao longo dos anos. O modelo de correlação é um dos mais utilizados, no qual uma série de modelos é construída para extrair as características das árvores em diferentes locais da imagem, levando em consideração suas propriedades geométricas e radiométricas. A partir destas características, é criado um procedimento de correlação de janela móvel, no qual é implementado para procurar as faces de melhor correspondência, de acordo com as características estabelecidas das árvores (GEBRESLASIE et al., 2011).

Outro método bastante adotado para promover detecção automática de árvores a partir de imagens de alta resolução espacial é a aplicação do filtro de máximos locais. Neste método, uma janela de busca é aplicada em todos os pixels da imagem, dentro desta janela, os pixels ou regiões com maiores valores de reflectância são considerados o topo ou o centro das árvores (GEBRESLASIE et al., 2011; WULDER; NIEMANN; GOODENOUGH, 2000). Quando adotado este método, é necessário definir o tamanho da janela de busca. Esta determinação pode ser de janela de forma fixa (3x3; 5x5; 7x7) ou forma variável, na qual utiliza semivariância para customizar o tamanho da janela de busca, de acordo com as características de textura dos pixels da imagem (FIGURA 6) caso a janela for muito reduzida, ocorrerão erros de comissão, no qual o algoritmo seleciona árvores inexistentes no conjunto de dados; por outro lado, caso a janela selecionada de busca seja muito grande, haverá erros de omissão de árvores dentro do povoamento (WULDER; NIEMANN; GOODENOUGH, 2000).

A escolha do tamanho da janela de busca é complexa (LI et al., 2012). Geralmente é feito com base no conhecimento prévio do tamanho de copa das árvores ou por aplicação de vários tamanhos de janelas de busca e avaliação do resultado final (WALLACE; LUCIEER; WATSON, 2014).

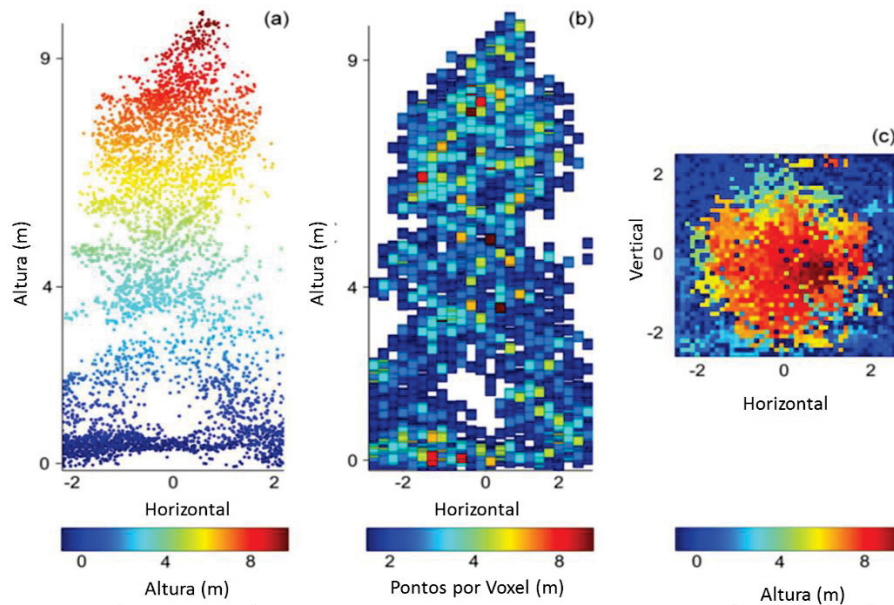
FIGURA 6 - EXEMPLO DA VARIAÇÃO DO NÚMERO TOTAL DE ÁRVORES DETECTADAS AO APLICAR O FILTRO DE MÁXIMAS LOCAIS EM IMAGEM IKONOS.



A) FILTRO DE MÁXIMA LOCAL COM JANELA FIXA DE DIMENSÃO 3X3. B) FILTRO DE MÁXIMA LOCAL COM JANELA DINÂMICA. FONTE: WULDER ET AL. (2000).

Quando utilizadas nuvens de pontos 3D, outros métodos foram desenvolvidos com algum sucesso nas taxas de detecção. Wallace et al. (2014) realizaram um estudo comparativo entre os métodos mais utilizados com esta finalidade aplicado a nuvens de pontos 3D obtidas de LiDAR acoplado a RPAS. Os autores classificaram os algoritmos de acordo com o formato dos dados de entrada obtidos a partir da nuvem: 1) nuvem original; 2) espaço voxel; 3) modelo digital de superfície do dossel (FIGURA 7).

FIGURA 7 - representação dos formatos trabalhados da nuvem de pontos 3D



FONTE: Wallace et al. (2014) adaptado.


Na utilização de nuvem de pontos 3D na aplicação direta de um algoritmo, o método mais utilizado é retratado no trabalho desenvolvido por Li et al. (2012), no qual utiliza máximos globais. Neste método, o ponto mais alto existente na nuvem de pontos normalizada é assumido como o topo da árvore mais alta do povoamento. A partir deste ponto, utilizado como “semente”, é definido um raio de busca para filtrar todos os pontos da nuvem pertencentes a esta árvore. Após a primeira filtragem, e determinação dos pontos pertencente à primeira árvore, estes são separados da nuvem original. Esta passa novamente pela filtragem até que a nuvem não contenha mais pontos a serem segmentados.

O algoritmo espaço voxel de detecção e delimitação (WANG et al., 2008) utiliza a nuvem de pontos projetada dentro de espaços voxels, onde cada voxel é atribuído de acordo com o número de pontos que contém (WALLACE; LUCIEER; WATSON, 2014). De forma simplificada, o algoritmo considera que o espaço voxel com maior densidade de pontos é o local mais provável do topo de uma árvore.

A abordagem mais utilizada atualmente para promover a detecção automática das árvores é baseada no método de filtros de máximos locais de janela fixa, nas quais os pixels com maior brilho dentro da janela de busca é assumido como o topo da copa (FIGURA 8) (MOHAN et al., 2017; REITBERGER et al., 2009; WULDER; NIEMANN; GOODENOUGH, 2000). Quando aplicado no modelo digital

de superfície do dossel, este filtro funciona da mesma forma quando aplicado em imagens multiespectrais, abordado nos parágrafos acima.

FIGURA 8 - Filtro de máxima local aplicado à superfície do dossel florestal.




Fonte: Reitberger ET AL. (2009).

#### 1.5.4 Filtro de Máximos Locais

O método de máximos locais para promover identificação de ápices de árvore é um assunto abordado na literatura a algum tempo, sendo um método já bastante difundido (KIM; RUDEMO, 1997). Inicialmente, começou a ser aplicado para esta finalidade em imagens aéreas e imagens de satélite de alta resolução espacial, e com o passar os anos e avanços tecnológicos, vêm sendo aplicados também para detecção automática de árvores a partir produtos extraídos de nuvens de pontos 3D, como os modelos digitais de superfície, no formato raster.

A lógica de funcionamento deste método de identificação de árvores parte do princípio de que nas imagens, os ápices das árvores possuem maiores valores de reflectância em níveis de cinza que os píxeis presentes em seu entorno (KIM; RUDEMO, 1997) (FIGURA 9).

FIGURA 9 - Visualização bidimensional e tridimensional de uma imagem de uma área de floresta em relação aos valores de reflectância presentes nos píxeis da imagem.



Fonte: Kim e Rudemo (1997).

A localização do ápice das árvores é realizada a partir de uma imagem pré-processada, após ação do filtro de suavização de Kernel. Este filtro é primeiramente utilizado para eliminação de ruídos da imagem, e posteriormente para filtragem e obtenção dos píxeis cujos valores de reflectância tenham sido superiores a um certo nível de reflectância previamente estabelecido. Os valores de reflectância assumidos como condizentes ao ápice das árvores são obtidos em função do histograma da imagem após filtragem de suavização de Kernel (KIM; RUDEMO, 1997; ZANDONÁ, 2006).


A partir dos valores de reflectância da imagem pré-processada, é aplicada uma janela de busca em todos os píxeis da imagem, afim de determinar se um dado pixel possui valores de reflectância condizentes com os de ápice de árvores em relação aos seus vizinhos (KIM; RUDEMO, 1997; WULDER; NIEMANN; GOODENOUGH, 2000). O pixel identificado com o maior valor de reflectância entre seus vizinhos é então classificado como sendo a localização de uma árvore (WULDER; NIEMANN; GOODENOUGH, 2000).

A lógica de funcionamento do filtro de máximos locais aplicado em imagens é a mesma quando aplicada em modelos de superfície rasterizados, obtidos a partir de nuvens de pontos 3D. O modelo de superfície é transformado em imagem, com um nível de resolução espacial condizente e com valores de reflectâncias referentes à altimetria da nuvem (eixo z) (FIGURA 10). A partir desta imagem do modelo de



superfície, o filtro é aplicado com a janela de busca de tamanho fixo, que pode ser de 3 x 3, 5 x 5, 7 x 7 ou 9 x 9 (MOHAN et al., 2017).

FIGURA 10 - DETECÇÃO DE ÁRVORES ATRAVÉS DO FILTRO DE MÁXIMA LOCAL APLICADO À SUPERFÍCIE DO DOSSEL FLORESTAL



Fonte: Reitberger et al. (2009).

#### 1.5.5 Filtro de Máximos Globais


O método de detecção de árvores através do filtro de máximos globais é aplicado diretamente em nuvens de pontos 3D. Nesta abordagem, são levadas em consideração as mudanças no espaço relativo entre árvores individuais em diferentes alturas para determinar um limite de árvore (WALLACE; LUCIEER; WATSON, 2014). Neste método, o ponto mais alto existente na nuvem de pontos normalizada é considerado como pertencente à primeira árvore, e todos os outros pontos são avaliados de acordo com um conjunto de critérios para determinar se eles pertencem a esta árvore atual (LI et al., 2012; WALLACE; LUCIEER; WATSON, 2014).

O critério mais importante utilizado para determinar se um ponto de uma determinada nuvem de pontos 3D pertence à uma árvore  $n$  (condizente com a máxima global daquela nuvem) é a aplicação de um raio de busca. Tal raio é projetado no plano ortogonal (2D) e todos os pontos existentes dentro deste raio é classificado como pertencente à árvore  $n$ . Uma vez que a árvore  $n$  foi segmentada,

ela é então separada da nuvem de pontos 3D e o filtro retorna a passar novamente, obtendo a árvore  $n+1$  e assim sucessivamente.

No trabalho de Li et al. (2012) o método de detecção de árvores a partir de filtros de máximos globais é explicado a partir da análise da FIGURA 11.

FIGURA 11 - DISTÂNCIA ENTRE O ÁPICE DE ÁRVORES COM COPAS ISOLADAS (A) E CONTÍGUAS (B).




Fonte: Li et al. (2012).

A distância entre o ápice de duas árvores é maior que a distância entre os pontos existentes em sua base, ou seja:  $d_{AB} > d_{CD}$ , independentemente se as árvores se encontram com copas entrelaçadas ou não. A partir desta lógica, uma distância mínima é definida (ou raio de busca), no qual estabelece que todos os pontos existentes dentro desta distância mínima em relação ao ápice da maior árvore da nuvem são pertencentes à esta árvore.

Outros critérios de classificação podem ser adicionados afim de obter melhora da detecção. Um exemplo deles foi utilizado por Li et al. (2012): o uso da distância entre um determinado ponto e o ápice das árvores (FIGURA 12).



FIGURA 12 - DISTÂNCIA ENTRE PONTOS A, B, C, D E REFERENTE A DUAS ÁRVORES



Fonte: Li et al. (2012).

A distância entre o ponto C e o ponto A (árvore mais alta e classificada) é menor que a distância entre C e o ponto B (segunda árvore ainda não classificada). Como  $d_{CA} < d_{CB}$ , o ponto C é classificado como pertencente à árvore A, e assim por diante, até a classificação total da nuvem de pontos 3D.


O algoritmo DAA funciona com base nos princípios de máximas globais, assim como o proposto por Li et al. (2012), e foi aplicado diretamente na nuvem de pontos normalizada, porém obedecendo a critérios próprios de classificação, critérios estes diferentes dos utilizados no algoritmo proposto por este autor. Os parâmetros de classificação utilizados pelo DAA são mostrados mais adiante.

## 1.6 MATERIAL E MÉTODOS

### 1.6.1 Áreas de estudo

Para verificação do comportamento do algoritmo na contagem automática de árvores, foram realizados testes em dois tipos de povoamentos de *Pinus spp.* em duas fases distintas de desenvolvimento: plantio jovem de 2 anos e plantio adulto de 11 anos recém desbastado (FIGURA 13).

FIGURA 13 - ORTOFOTOS DAS ÁREAS DE ESTUDO. A) PLANTIO JOVEM DE *Pinus spp.*; B) PLANTIO ADULTO RECÉM DESBASTADO DE *Pinus spp.*



FONTE: A autora (2018)

O plantio jovem está localizado no estado de Santa Catarina, no município de Monte Castelo (O 50° 18' 32,34" e S 26° 40' 29,87" S DATUM SIRGAS 2000). As características do plantio são apresentadas na TABELA 1.

TABELA 1 - CARACTERÍSTICAS DO TALHÃO JOVEM SELECIONADO PARA APLICAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DE NUVEM DE PONTOS DE IMAGENS ÓPTICAS DE RPAS.

Características do plantio jovem	Valores
Área	4,51 ha
Espaçamento	2,5m X 2,5 m
Idade	2 anos
Desbaste	Não realizado
Densidade de plantio	1.600 árvores/ha

As áreas referentes ao plantio foram separadas do restante da vegetação presente na nuvem de pontos 3D. Nesse plantio, o ajuste dos parâmetros foi realizado em três unidades amostrais de formato circular.

O levantamento aéreo com RPAS em plantio adulto foi realizado em um talhão de *Pinus* spp. recém desbastado (TABELA 2) localizado no município de São Mateus do Sul, estado do Paraná, Brasil (O 50° 35' 27,070" e S 25° 55' 36,291" DATUM SIRGAS 2000).

TABELA 2 - CARACTERÍSTICAS DO TALHÃO ADULTO SELECIONADO PARA APLICAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DE NUVEM DE PONTOS 3D DE IMAGENS ÓPTICAS DE RPAS.

Características do Talhão	Valores
Área	4,5 ha
Espaçamento	2m x 2,5 m
Idade	11 anos
	Misto aos 11 anos (sistemático de 5 <sup>a</sup>
Desbaste	linha e seletivo)
Densidade após desbaste	750 árvores/ha

O talhão adulto selecionado foi dividido em blocos a partir da quinta linha do desbaste sistemático e assim cada bloco corresponde a quatro linhas de plantio. Dois blocos subsequentes foram selecionados de forma aleatória como amostras de treinamento para fins de validação do desempenho do algoritmo e ajuste dos parâmetros condizentes com as características deste povoamento. O único critério

utilizado para a escolha dos blocos de amostras de treinamento foi a exclusão dos blocos de borda do talhão (B1 e B12) (FIGURA 14).

FIGURA 14 - IMAGEM EM PERSPECTIVA DO TALHÃO ADULTO UTILIZADO PARA IMPLEMENTAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES.



FONTE: A autora (2018)

## 1.6.2 Coleta de dados

### 1.6.2.1 Levantamento da quantidade de indivíduos

No plantio jovem, foi realizada contagem das árvores pela ortofoto do talhão, de forma manual, por meio de fotointerpretação. O resultado da contagem foi utilizado como testemunha para comparação com o resultado da contagem automática obtida pelo algoritmo.

No talhão adulto, foi realizado tanto censo florestal por levantamento em campo quanto contagem de árvores por fotointerpretação da ortofoto, para obtenção do número total de árvores existentes.

### 1.6.2.2 Levantamento das fotografias aéreas

O plano de voo foi realizado por meio do uso do *Drone quadcopter* DJI Phantom 4 PRO, cuja câmera integrada possui distância focal de 24 mm e 20 MP de

resolução. O sensor desta câmera possui dimensões de 8 x 11 mm e as imagens geradas possuem dimensão de 3.648 x 4.864 pixels. (FIGURA 15).

FIGURA 15 - DRONE QUADCOPTER DJI PHANTOM 4 PRO UTILIZADO NA OBTENÇÃO DAS IMAGENS.



FONTE: [www.dji.com](http://www.dji.com)

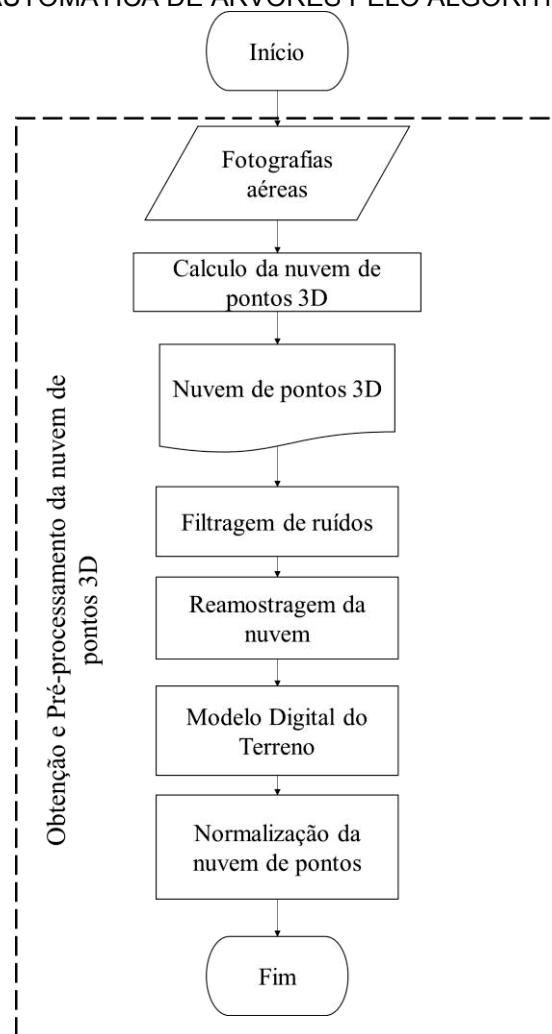
No plantio jovem, o voo foi realizado no dia 19 de setembro de 2017, no período do dia correspondente à janela de voo (entre 10h e 14h). A altitude de voo foi de 100 metros, com sobreposição lateral e 80% e frontal de 85%. A janela de voo é um fator importante para obtenção de imagens a partir de VANT, pois neste período, o Sol encontra-se a pino, de forma a minimizar o efeito das sombras nas fotografias, pois geram erros na profundidade da nuvem de pontos durante o processamento. Harwin et al. (2015), ao utilizarem técnicas de múltipla visão estereoscópica, visão computacional e Fotogrametria digital, demonstraram que a densidade da nuvem de pontos 3D é diretamente proporcional ao número de feições combinadas, textura de superfície, oclusões e mudanças de iluminação.

No plantio adulto, o levantamento das fotografias aéreas foi realizado por meio de dois voos, em diferentes alturas: a primeira altura de voo definida foi de 100 e a segunda de 130 metros em relação ao solo, com sobreposição frontal de 80% e lateral de 70%. O levantamento das fotografias aéreas foi realizado na modalidade *Cross Grid*, uma modalidade de levantamento que consiste em obtenção de fotos aéreas com voo cruzado na área de interesse. Essa modalidade de voo leva ao aumento da cobertura das fotos no espaço objeto e, consequentemente, ao seu grau de detalhamento. Os voos foram realizados na janela de voo do dia 23 de junho de 2017.

### 1.6.3 Pré-processamento da nuvem de pontos 3D

Para obtenção e pré-processamento das nuvens de pontos obtidas a partir de fotografias aéreas, foram adotados os procedimentos ilustrados no fluxograma da FIGURA 16.

FIGURA 16 - FLUXOGRAMA DE REPRESENTAÇÃO DAS ETAPAS DO PROCEDIMENTO ADOTADO PARA OBTENÇÃO DA NUVEM DE PONTOS APTA PARA PASSAR PELA DETECÇÃO AUTOMÁTICA DE ÁRVORES PELO ALGORITMO.



FONTE: A autora (2018)

#### 1.6.3.1 Obtenção das nuvens de pontos 3D

A visão computacional associada a Fotogrametria digital, descreve o espaço objeto por meio da restituição do espaço imagem, a partir das características de sobreposição, iluminação e distribuição de cores existentes nas fotografias (SZELISKI, 2011). As nuvens de pontos 3D foram geradas automaticamente a partir



do conjunto de fotos aéreas, pelo uso do *Software* Agisoft Photoscan, um programa com pacote de visão computacional de uso comercial, no qual usa algoritmos próprios com grande eficiência para geração de nuvens de pontos 3D a partir de imagens estereoscópicas (DANDOIS; ELLIS, 2013).

O *software* funciona a partir do princípio *Structure From Motion*, onde os pontos são extraídos automaticamente de fotos individuais, e posteriormente identificando seus pontos homólogos no modelo estereoscópico; após a obtenção destes “pontos-chave”, é utilizado um pacote algoritmos de ajuste do próprio *software* para estimar e otimizar suas características tridimensionais, juntamente com a localização e orientação das câmeras e seus parâmetros internos (FIGURA 17) (DANDOIS; ELLIS, 2013).


FIGURA 17 - REPRESENTAÇÃO DO FUNCIONAMENTO DO SISTEMA *STRUCTURE FROM MOTION*.



Fonte: Dandois e Ellis (2013)

O pré-processamento das fotos aéreas no *Agisoft Photoscan* resultou em duas nuvens de pontos 3D densas, sendo uma de cada povoamento estudado. As nuvens produzidas consistem em um conjunto de pontos 3D em um sistema de coordenadas arbitrário, porém com geometria internamente consistente, com informações RGB extraídos de cada ponto das fotos de entrada (FIGURA 18) (DANDOIS; ELLIS, 2013).

FIGURA 18 - Nuvens de pontos 3D obtidas a partir de técnicas de visão computacional em imagens ópticas aéreas.




(A): Nuvem de pontos 3D do plantio jovem de *Pinus* spp. (B): nuvem de pontos 3D do plantio adulto de *Pinus* spp.

FONTE: A autora (2018)

Os efeitos da luminosidade nas fotografias aéreas têm grande impacto na qualidade da nuvem de pontos 3D. A influência da fonte externa de iluminação (sol) no momento de obtenção das fotografias aéreas é um fator de elevada importância quando se objetiva informações do solo no povoamento florestal. Pelo fato de as imagens serem obtidas a partir de sensores passivos, no caso das câmeras fotográficas digitais, a luminosidade exerce grande influência na qualidade do resultado final das imagens, e consequentemente nas nuvens de pontos 3D obtidas a partir destas. O comparativo entre as nuvens de pontos 3D obtidas a partir de imagens com baixa e alta luminosidade pode ser observado na FIGURA 19.



FIGURA 19 - A) NUVEM DE PONTOS OBTIDA A PARTIR DE FOTOGRAFIAS AÉREAS COM POUCA ILUMINAÇÃO SOLAR OU ALTA INCIDÊNCIA DE SOMBRAS; B) NUVEM DE PONTOS 3D OBTIDA A PARTIR DE FOTOGRAFIAS AÉREAS COM ALTA LUMINOSIDADE E POUCA SOMBRA.



FONTE: A autora (2018)

A partir da nuvem de pontos obtida, foram selecionados para passar pelas etapas de pré-processamento apenas os pontos da nuvem pertencentes ao talhão, excluindo-se os pontos pertencentes a outro tipo de uso do solo, como florestas nativas, estradas, construções, etc.

### 1.6.3.2 Filtragem das nuvens

As nuvens de pontos obtidas de imagens ópticas estão sujeitas a grande ocorrência de ruídos ou *outliers*. Para correção destes erros, foi aplicado o algoritmo *StatisticalOutlierRemoval* (SOR) (RUSU et al., 2008), implementado no *software open source* CloudCompare 2.9, no qual utiliza estatística dos pontos vizinhos para remover *outliers*.

O SOR funciona através de duas fases de interação com o arquivo de entrada: durante a primeira interação, calcula a distância média entre cada ponto e seus  $k$  vizinhos mais próximos. O valor de  $k$  é configurado pelo usuário. Em seguida, a média e o desvio padrão de todas estas distâncias são computadas para determinar a distância limite entre os pontos. Durante a próxima interação, os pontos são classificados como *inlier* ou *outlier* de acordo com o limite calculado: se o ponto estiver acima do limite, será considerado *outlier*, e se estiver abaixo, *inlier* (PCL Library).

$$MaxDist = \frac{\sum xi}{n} \pm \alpha \sqrt{\frac{\sum (xi - \bar{x})^2}{n-1}}$$

Em que:

MaxDist: Distância limite entre pontos;

$\alpha$ : constante multiplicadora do desvio padrão. Depende do tamanho da vizinhança analisada (detalhes ver RUSU et al., 2008).

### 1.6.3.3 Reamostragem das nuvens de pontos 3D

Muitas vezes, a nuvem de pontos obtida a partir de fotografias ópticas apresenta grande densidade de ponto, com alto grau de detalhamento das superfícies. Porém esta grande quantidade de informações pode vir a ser redundante, principalmente em superfícies com pouca variação. Se processar tamanha quantidade de dados, é necessário grande capacidade de armazenamento e recursos computacionais, portanto, para ser efetivo, um modelo deve ser bem balanceado, no que se refere à resolução e armazenagem (KERSTING et al., 2004).

Com finalidade de redução de recurso computacional, tempo de processamento e redundância de dados, são adotados processos de amostragem em nuvens de pontos com alta densidade. Porém este processo de amostragem deve ser cuidadosamente considerado, pois o mesmo deve ser capaz de representar o fenômeno como um todo sem a perda de informações, que podem condenar a amostragem (MIRANDA, 2017).


No presente estudo, ambas as nuvens de pontos 3D foram reamostradas, no formato aleatório simples, para 1% do total dos pontos, de forma a reduzir o tempo computacional necessário para o processamento desta sem perda de informações importantes sobre os povoamentos estudados.

#### 1.6.3.4 Modelo Digital do Terreno

O Modelo Digital do Terreno é obtido a partir de dados espaciais que representam a superfície a ser modelada (MIRANDA, 2017). As nuvens de pontos 3D podem funcionar como base de dados de referência para geração de um modelo que representem a distribuição da superfície, porém esta pode apresentar pontos que não representam a camada a ser modelada. Portanto estas nuvens devem passar por um processo de filtragem para extração apenas dos pontos de interesse. Para tanto, as da nuvens de pontos 3D obtidas foram submetida ao algoritmo *Cloth Simulation Filtering* (CSF) (ZHANG et al., 2016), desenvolvido originalmente para filtragem de pontos correspondentes ao solo de dados laser aéreo, implementado no *software* livre CloudCompare 2.9 (FIGURA 20).

O CSF extrai pontos referentes ao solo através de modelagem da malha “*Cloth modeling*”, onde simula-se uma malha sobre a nuvem inversa, resultando em uma base para classificação de pontos de solo e não solo.

FIGURA 20 - Representação do funcionamento do algoritmo *Cloth Simulation Filtering*.



FONTE: ZHANG ET AL. (2016).

O CSF precisa ser ajustado para cada tipo de nuvem e características do terreno a ser modelado. Este algoritmo possui duas fases de ajuste destes parâmetros: parâmetros gerais, que precisa ser configurado cada vez que o programa é executado, que corresponde ao tipo de relevo do terreno a ser segmentado; e os parâmetros avançados, que pode e deve ser executado de acordo com as necessidades do usuário. Neste caso, os parâmetros consistem em *Cloth resolution* (resolução do grid da malha utilizada pelo algoritmo); máximas interações (*Max iterations*) e limiar de classificação (*Classification threshold*), que se refere a um limite para classificação de pontos entre solo e não solo, baseado nas distâncias entre os pontos do terreno simulado.

### 1.6.3.5 Normalização das nuvens de pontos 3D

Com objetivo de eliminar os efeitos das variações de altimetria nos povoamentos estudados, consequentemente, obter as alturas absolutas das árvores, foi necessária a normalização da nuvem de pontos em relação ao MDT (Modelo Digital do Terreno) do talhão. Neste processo, os pontos pertencentes ao solo, obtidos através da filtragem CSF, passam por processo de triangulação irregular (TIN – *Triangulated Irregular Network*), para formação da superfície do terreno, ou MDT. Os pontos da nuvem não pertencentes ao terreno (MDS) são subtraídos do MDT, e assim resulta a normalização do ponto (WANG; WEINACKER; KOCH, 2008).

$$\text{Nuvem Normalizada} = \text{MDS} - \text{MDT}$$

O resultado do processo de normalização do plantio adulto de *Pinus spp.* é mostrado na FIGURA 21.

FIGURA 21 - NORMALIZAÇÃO DA NUVEM DE PONTOS DO TALHÃO ADULTO.




A) Nuvem de pontos original obtida a partir de fotos aéreas; B) Nuvem de pontos após processo de normalização, vista lateral.  
FONTE: A autora (2018)

Estabeleceu-se que o arquivo de entrada para o funcionamento do algoritmo apresentado seja a nuvem de pontos 3D normalizada com pontos referentes apenas a porção do dossel florestal, no caso de plantios adultos, e pontos referentes apenas às copas das árvores, no caso de plantios jovens, descartando-se os pontos referentes ao solo e sub-bosques nos plantios.

#### 1.6.4 Algoritmo de Detecção Automática de Árvores (DAA)

A partir das nuvens normalizadas, resultantes do pré-processamento, foram selecionados e extraídos os pontos pertencentes apenas à porção das copas das árvores, ou dossel florestal, no caso do povoamento adulto. O DAA foi desenvolvido para atuar apenas nesta porção da nuvem de pontos, para desta forma, melhorar seu desempenho de processamento. O resultado do processo de normalização e extração do dossel pode ser observado na FIGURA 22. Foram excluídos todos os pontos abaixo de 12, no povoamento adulto, e 0,5 no povoamento jovem.

FIGURA 22 - NUVENS DE PONTOS 3D PRÉ-PROCESSADAS UTILIZADAS COMO ARQUIVO DE ENTRADA PARA A APLICAÇÃO DO ALGORITMO.

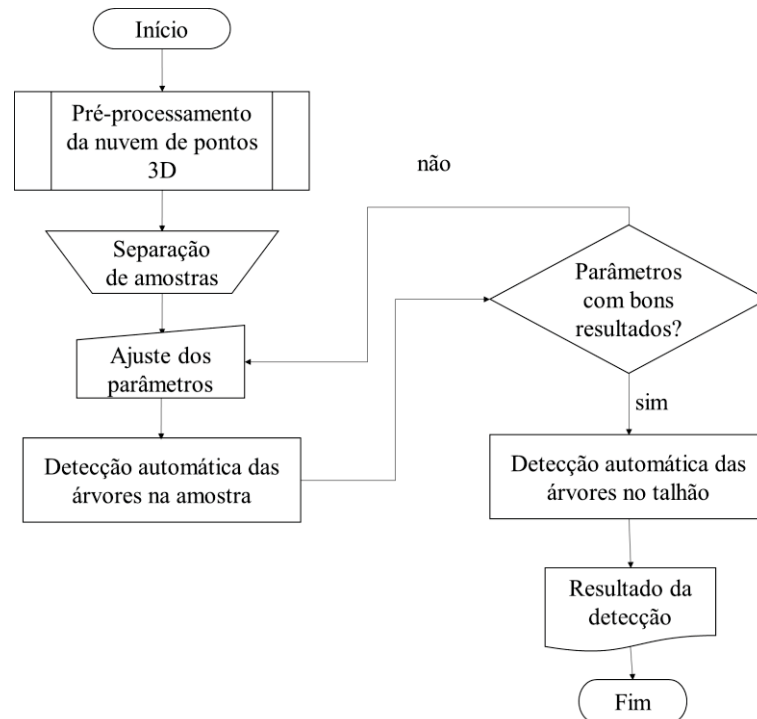


a) Nuvem de pontos 3D do dossel normalizada do plantio jovem em visão em perspectiva; b) Nuvem de pontos 3D do dossel normalizada do plantio jovem em visão longitudinal. C) Nuvem de pontos 3D do dossel normalizada do plantio adulto em visão em perspectiva; D) Nuvem de pontos 3D do dossel normalizada do plantio adulto em visão longitudinal.

FONTE: A autora (2018)

O algoritmo desenvolvido para detecção automática de árvores nas áreas foi aplicado seguindo as etapas do fluxograma (FIGURA 23).

FIGURA 23 - FLUXOGRAMA DAS ETAPAS DE COLETA DE IMAGENS, PRÉ-PROCESSAMENTO, AJUSTE DE PARÂMETROS E DETECÇÃO DAS ÁRVORES NA NUVEM DE PONTOS DO TALHÃO OBTIDA DE IMAGENS ÓPTICAS DE RPAS.



FONTE: A autora (2018)

Muitos algoritmos para detecção automaticamente de árvores em nuvens de pontos 3D seguem o princípio de máximos locais, no qual o alvo é o ponto mais alto dentro de uma determinada janela predefinida de busca, porém a definição do tamanho ideal da janela, especialmente em dosséis florestais mais densos, é complexa (LI et al., 2012), pois não assegura que o máximo local seja de fato o ápice de uma copa.

O método para detecção automática de árvores apresentado neste trabalho fundamenta-se no princípio de máximos globais, no qual obtemos pontos mais altos a partir da totalidade da nuvem de pontos. Este ponto mais alto é então definido como o topo da árvore mais alta. Este ponto funciona como “semente” na aplicação de raio de busca com distância predefinida. Nos métodos de segmentação automática de árvores a partir de máximas globais, o raio de busca ( $r$ ) é definido de acordo com as características do espaçamento entre árvores (WALLACE; LUCIEER; WATSON, 2014). Os pontos alocados dentro deste raio de busca são então classificados como pertencente à árvore do ponto semente. Após a classificação os

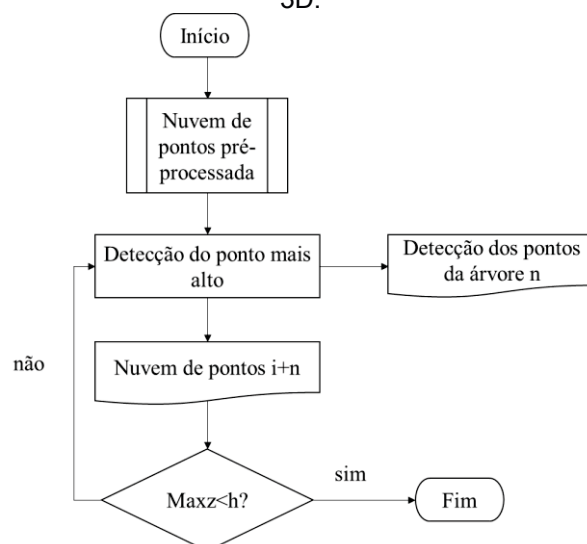
pontos pertencentes as árvores são separados e removidos da nuvem de pontos inicial. Subsequentemente, o ponto mais alto da nuvem de pontos 3D remanescente pode ser utilizado como o topo da segunda árvore mais alta, e assim por diante.

Embora o DAA seja embasado no algoritmo de máximos globais proposto por Li et al. (2012), os parâmetros criados para o funcionamento deste para possibilitar a detecção de árvores a partir da utilização de nuvens de pontos 3D providas de imagens ópticas de RPAS são diferentes. Os parâmetros utilizados neste trabalho são:

- $H_{\text{dossel}}$ : a altura inferior do dossel do povoamento (FIGURA 25);
- $\text{MaxZ}$ :  $H_{\text{dossel}}$  acrescido de 1, que corresponde aos pontos na nuvem que possuem menor valor no eixo z passível de ser classificado como topo de uma árvore. Este parâmetro foi criado com finalidade impossibilitar que o algoritmo erroneamente classifique um ponto presente abaixo do topo da árvore como um falso positivo;
- $r$ : raio de busca do algoritmo, tomado a partir do maior ponto no eixo z detectado na nuvem de pontos 3D.

O fluxograma da FIGURA 24 ilustra o funcionamento deste algoritmo.

FIGURA 24 - ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES EM NUVEM DE PONTOS 3D.



FONTE: LI et al. (2012). Adaptado.

Para o povoamento jovem, o  $\text{MaxZ}$  não foi utilizado, uma vez que na nuvem deste povoamento não há entrelaçamento de copas, portanto, apenas os pontos referentes as árvores estão presentes nesta nuvem. O algoritmo proposto para a



detecção automática de árvores foi escrito na linguagem de programação Python, com uso do pacote Arcpy (ESRI). O funcionamento é baseado na seguinte lógica:

```

Início:
    Nuvem i = Importa (Nuvem de pontos);

Para Nuvem i:

    De Nuvem i:
        MAxZn = MaxZ (Nuvem i);

        Se MAxZn ≥ Hdossel:

            Arvn = raio. MAxZn (Nuvem i);
            Nuvem i = Nuvem i - Arvn;

        Se não:
            Stop

    i+ = 1
  
```

A FIGURA 25 ilustra como o parâmetro  $H_{\text{dossel}}$  é obtido a partir da nuvem de pontos pré-processada. Todos os parâmetros do DAA devem ser definidos de acordo com as características e espaçamento do povoamento florestal.

FIGURA 25 - REPRESENTAÇÃO DA OBTENÇÃO DO PARÂMETRO  $H_{\text{DOSSSEL}}$  NA NUVEM DE PONTOS DO PLANTIO ADULTO.



FONTE: A autora (2018)

O DAA classifica ordenadamente da árvore mais alta para a menor, até que a nuvem em processo não apresente pontos para serem classificados. Na fase final do processamento do algoritmo DAA, apenas o ponto mais alto pertencente às árvores é mantido, assumindo que o valor do eixo z destes pontos correspondem às alturas totais das árvores automaticamente detectadas.

A partir deste ponto, os capítulos seguintes utilizam as nuvens de pontos 3D pré-processadas, prontas para ação do algoritmo de detecção automática de árvores DAA, tanto em plantios jovens (Capítulo 2) quando em plantio adulto (Capítulo 3).

## REFERÊNCIAS

- ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138–146, 2013.
- BEIS, J. S.; LOWE, D. G. Shape indexing using approximate nearest-neighbour search in high-dimensional. **Computer Vision and Pattern Recognition, 1997. Proceedings.** p. 1000-1006, 1997.
- BROWN, M.; LOWE, D. G. Recognising Panoramas. **Department of Compute Science.** University of British Columbia. Vancouver, Canada. 2002.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.
- DANDOIS, J. P. et al. What is the point? Evaluating the structure, color, and semantic traits of computer vision point clouds of vegetation. **Remote Sensing**, v. 9, n. 4, p. 1–20, 2017.
- DANDOIS, J. P.; ELLIS, E. C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**, v. 136, p. 259–276, 2013.
- FRITZ, A.; KATTENBORN, T.; KOCH, B. UAV-BASED PHOTOGRAMMETRIC POINT CLOUDS -TREE STEM MAPPING IN OPEN STANDS IN COMPARISON TO TERRESTRIAL LASER SCANNER POINT CLOUDS. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XL-1/W2, n. September, p. Pages: 141-146, 2013.
- GAVA, Christiano. Dense 3D Reconstruction. 2011. Technische Universität KaisersLaurern, Lecture 3D computer vision. KaisersLaurern.
- GEBRESLASIE, M. T. et al. Individual tree detection based on variable and fixed window size local maxima filtering applied to IKONOS imagery for even-aged Eucalyptus plantation forests. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4141–4154, 2011.
- GETZIN, S.; NUSKE, R. S.; WIEGAND, K. Using Unmanned Aerial Vehicles (UAV) to Quantify Spatial Gap Patterns in Forests. p. 6988–7004, 2014.
- HARTLEY, R., GUPTA, R. AND CHANG, T. Stereo from uncalibrated cameras, Proc. IEEE Conf. Comp. Vision Patt. Recog., Champaign, IL, pp. 761-764, 1992.
- HARTLEY, R.; ZISSERMAN, A. **Multiple View Geometry.** New York: United States of America, 2004. v. 53
- HARWIN, S.; LUCIEER, A. an Accuracy Assessment of Georeferenced Point Clouds Produced Via Multi-View Stereo Techniques Applied To Imagery Acquired Via Unmanned Aerial Vehicle. **ISPRS - International Archives of the Photogrammetry,**

**Remote Sensing and Spatial Information Sciences**, v. XXXIX-B7, n. September, p. 475–480, 2012.

HARWIN, S.; LUCIEER, A.; OSBORN, J. The impact of the calibration method on the accuracy of point clouds derived using unmanned aerial vehicle multi-view stereopsis. **Remote Sensing**, v. 7, n. 9, p. 11933–11953, 2015.

JIANG, H. et al. Papaya Tree Detection with UAV Images Using a GPU-Accelerated Scale-Space Filtering Method. **remote sensing Article**, v. 9, n. 721, p. 1–13, 2017.

KERSTING, J. et al. Filtragem de Modelos Digitais de Superfície derivados da varredura a laser usando a triangulação de Dalaunay. **I Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação - SIMGEO**, v. 1, n. Burrough 1986, p. 1–10, 2004.

LI, W. et al. A New Method for Segmenting Individual Trees from the Lidar Point Cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75–84, 2012.

LOWE, D. G. Object recognition from local scale-invariant features. **International Journal of Computer Vision**. p. 1150 - 1157, 1999.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, v. 60, n. 2, p. 91–110, 2004.

MIRANDA, G. H. B. **ANÁLISE DE AMOSTRAGEM E INTERPOLAÇÃO NA GERAÇÃO**. [s.l.] Universidade Federal de Viçosa, 2017.

MOHAN, M. et al. Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. **Forests**, v. 8, n. 9, p. 340, 2017.

MULAC, B. L. Remote sensing applications of unmanned aircraft: challenges to flight in United States airspace. **Geocarto International**, v. 26, n. 2, p. 71–83, 2011.

NEX, F.; REMONDINO, F. UAV for 3D mapping applications: a review. **Appl Geomat**, p. 1–15, 2014.

PULITI, S. et al. Inventory of Small Forest Areas Using an Unmanned Aerial System. p. 9632–9654, 2015.

REITBERGER, J. et al. 3D segmentation of single trees exploiting full waveform LIDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 6, p. 561–574, 2009.

RUSU, R. B. et al. Towards 3D Point cloud based object maps for household environments. **Robotics and Autonomous Systems**, v. 56, n. 11, p. 927–941, 2008.

SHAHBAZI, M. et al. Uav-Based Point Cloud Generation for Open-Pit Mine Modelling. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XL-1/W4, p. 313–320, 2015.

SIEBERT, S.; TEIZER, J. Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system. **Automation in Construction**, v. 41, p. 1–14, 2014.

SOTIER, B. High resolution aerial images from UAV for forest applications State-of-the-Art. **Alpine Space. Project**, v. 232FR, n. 2, 2014.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. Springer ed. London: Springer-Verlag London, 2011.

TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, p. 791–797, 2015.

TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 2012.

WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 12, p. 7619–7628, 2014.

WANG, Y. et al. Lidar point cloud based fully automatic 3D single tree modelling in forest and evaluations of the procedure. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVII, n. June 2008, p. 45–52, 2008.

WANG, Y.; WEINACKER, H.; KOCH, B. A Lidar point cloud based procedure for vertical canopy structure analysis and 3D single tree modelling in forest. **Sensors**, v. 8, n. 6, p. 3938–3951, 2008.

WEB OF SCIENCE. Disponível em: <<https://webofknowledge.com/>>. Acessado em 25 de fevereiro de 2018.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. Local maximum filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. **Remote Sensing of Environment**, v. 73, n. 0, p. 103–114, 2000.

XIANG, H.; TIAN, L. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle ( UAV ). **Biosystems Engineering**, v. 108, n. 2, p. 174–190, 2011.

ZHANG, W. et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. **Remote Sensing**, v. 8, n. 6, p. 1–22, 2016.

ZHENGYOU, Z. Determining the epipolar geometry and its uncertainty: a review. **International Journal of Computer Vision**. v. 27. p. 161 - 198, 1997.

## **2 DETECÇÃO AUTOMÁTICA DE ÁRVORES EM UM PLANTIO JOVEM DE *Pinus* spp. A PARTIR DE NUVENS DE PONTOS 3D OBTIDAS DE IMAGENS ÓPTICAS DE RPAS (REMOTELY PILOTED AIRCRAFT SYSTEM)**

### **RESUMO**

O número de árvores jovens existentes em um povoamento florestal é de extrema importância para obtenção de estimativas de produtividade e planejamento de atividades futuras. A obtenção desta informação ocorre principalmente por meio de contagem de árvores em campo ou contagem manual por interpretação de ortofoto de imagens ópticas obtidas de RPAS. Com objetivo de testar um método automatizado para realização desta atividade, este trabalho apresenta e analisa o funcionamento do algoritmo DAA (Detecção Automática de Árvores) para contabilização de árvores a partir de nuvens de pontos 3D geradas de imagens ópticas de RPAS. O plantio estudado consiste em um talhão de 4,2 ha de 2 anos de idade da espécie *Pinus spp.* O DAA foi aplicado na nuvem de pontos 3D pré-processada, com separação de amostras de treinamento para ajuste dos parâmetros do algoritmo. Como resultado, o DAA obteve-se 91% do total de árvores em relação às contabilizadas pela ortofoto. O F-score do algoritmo para o talhão estudado apresentou valor de 0,95, em uma escala de 0 a 1, mostrando a boa performance do algoritmo no talhão.

**Palavras-chave:** Automatização. Contagem de árvores. Fotogrametria Digital. Inventário.

## ABSTRACT

The number of seedlings existing in a forest planting is extremely important to obtaining estimates of productivity and planning of future activities. The obtaining of this information occurs mainly by counting of seedlings in the field or manual counting by orthophoto interpretation of optical images obtained by RPAS. Aiming to test an automated method to perform this activity, this work presents and analyzes the DAA (Detecção Automática de Árvores) algorithm for counting seedlings from clouds of 3D points generated from RPAS's optical images. The studied planting consists of a 4.2 ha 2-year-old plot of the *Pinus taeda* species. The DAA was applied in the pre-processed 3D dots cloud, with separation of training samples to adjust the algorithm parameters. As a result, the DAA obtained 91% of the total seedlings in relation to those counted by orthophoto. The F-score of the algorithm for the planting studied presented a value of 0.95, on a scale of 0 to 1, showing the good performance of the algorithm in the field.

**Key-words:** Automation. Digital Photogrammetry. Inventory. Seedlings.

## 2.1 INTRODUÇÃO

A quantidade de indivíduos existentes em uma área consiste em informação importante para auxílio na assertividade de estimativas de produção futura. Nesse sentido, as taxas de sobrevivência populacional de mudas e árvores jovens têm grande valor para planejamento de inventários florestais, pois permite identificar previamente a mortalidade e garantir que a silvicultura possa intervir a tempo, para que no futuro os plantios sejam mais homogêneos (RUZA; et al., 2017).

O uso do Sensoriamento Remoto e Fotogrametria serve como auxílio no processo de obtenção de número de indivíduos existentes no povoamento florestal. Muitos métodos de contagem de árvores foram desenvolvidos através dos anos, tanto através de imagens obtidas de sensores orbitais quanto de fotografias aéreas, como através de produtos da Fotogrametria digital, como nuvens de pontos 3D e Modelo Digital de Superfície.

A possibilidade recente do uso de RPAS por civis possibilitou a aquisição de uma nova plataforma de sensores remoto (COLOMINA; MOLINA, 2014). Neste contexto, o uso de RPAS ou VANT (Veículos Aéreos Não Tripulados) na aquisição de fotografias aéreas pode gerar produtos de elevada importância para a área florestal, como para obtenção de nuvens de pontos 3D a baixo custo, funcionando como uma alternativa à nuvem de pontos 3D derivada de LASER aerotransportado (LESLAR, 2015; ROSNELL; HONKAVAARA, 2012). Estudos mostram a aplicabilidade de nuvem de pontos 3D derivadas de fotografias aéreas em florestas, possibilitando a obtenção de informações relevantes, como altura média (ZARCO-TEJADA et al., 2014), biomassa (SKOWRONSKI et al., 2014), volume (CHEN et al., 2007) e o censo das árvores (KOCH et al., 2006; WALLACE et al., 2014).

A nuvem de pontos 3D demonstra ser uma fonte de dados valiosa para criação de complexas estruturas em três dimensões (HARWIN; LUCIEER, 2012). A utilização desta fonte de dados obtida de forma simples através de imagens com alta sobreposição resulta em um instrumento poderoso de Fotogrametria e Sensoriamento Remoto (DANDOIS; ELLIS, 2013).

Diante do exposto, o presente estudo teve como objetivo aplicação do DAA com finalidade de detecção de árvores em um plantio jovem de *Pinus spp.* a partir de nuvens de pontos 3D derivadas de imagens ópticas obtidas de RPAS.




## 2.2 MÉTODOS

O algoritmo DAA (Detecção Automática de Árvores) foi aplicado na nuvem de pontos 3D pré-processada da área de plantio jovem de *Pinus* spp. de 2 anos de idade. Para possibilitar o funcionamento correto do algoritmo no povoamento, primeiramente foi realizado ajuste dos parâmetros do algoritmo, através de amostras de treinamento na nuvem de pontos 3D do plantio. Após a obtenção dos parâmetros, o algoritmo foi então aplicado em toda a área.

### 2.2.1 Ajuste dos parâmetros do DAA

O ajuste dos parâmetros foi realizado em três unidades amostrais de formato circular (FIGURA 26). Tais unidades foram pré-estabelecidas pela alocação de três pontos aleatórios na ortofoto e aplicação de um raio de 18 metros a partir destes pontos. Foram contabilizadas na ortofoto, de forma manual, os indivíduos encontrados dentro destas unidades amostrais e confrontadas com o número de indivíduos detectados pelo algoritmo nestas amostras. O ajuste foi finalizado quando o número de indivíduos detectados automaticamente pelo algoritmo atingiu níveis aceitáveis de acurácia, quando comparado ao número contabilizados na ortofoto.

FIGURA 26 - DISPOSIÇÃO DAS UNIDADES AMOSTRAIS UTILIZADAS PARA AJUSTE DE PARÂMETROS DO DAA

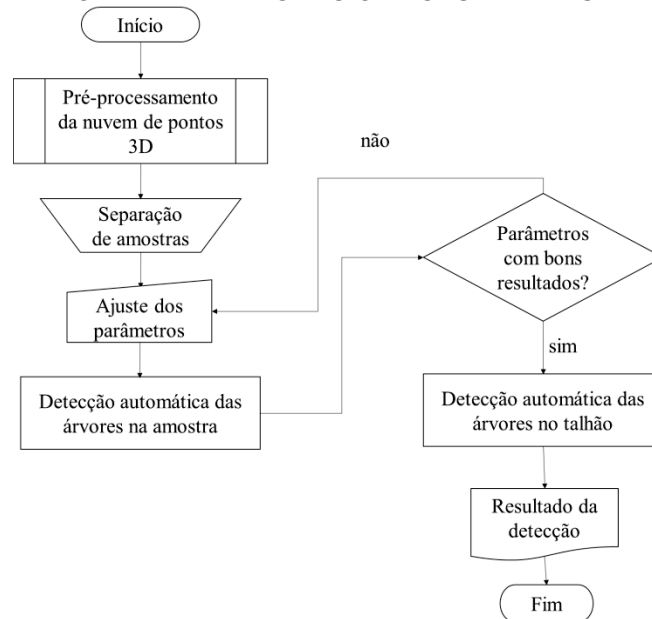


FONTE: A autora (2018)

A realização de ajuste de parâmetros para as amostras de treinamento consiste em um passo de extrema importância e estudo minucioso das características de cada povoamento a ser estudado. O erro nestes ajustes pode causar subestimação do número total de árvores ou superestimação destes. As amostras utilizadas consistem em porções menores do talhão com características do povoamento inteiro. Desta forma, é possível que rapidamente haja o processamento e visualização dos resultados finais e comparação com uma conferência manual destas árvores através da análise da ortofoto.

Uma vez os parâmetros corretamente ajustados, o passo seguinte é a aplicação do algoritmo no povoamento por inteiro. Caso o resultado do ajuste dos parâmetros ainda não esteja aceitável, é realizado um novo processo de ajuste, até que estes produzam resultados que satisfaçam a necessidade do usuário do algoritmo, conforme fluxograma mostrado na FIGURA 27.

FIGURA 27 - FLUXOGRAMA DAS ETAPAS DE COLETA DE IMAGENS, PRÉ-PROCESSAMENTO, AJUSTE DE PARÂMETROS E DETECÇÃO DAS ÁRVORES NA NUVEM DE PONTOS DO TALHÃO OBTIDA DE IMAGENS ÓPTICAS DE RPAS.



FONTE:

### 2.2.2 Avaliação do algoritmo no plantio jovem

A acurácia da detecção foi analisada de acordo com o número de árvores corretamente segmentadas, erros de comissão e omissão gerados pelo algoritmo em comparação com as contabilizadas através da fotointerpretação da ortofoto.

Tal como em Li et al. (2012) foram calculadas taxas de recall ( $r$ ) (Equação 1) precisão ( $p$ ) (Equação 2), e teste F-score (Equação 3). O teste F-Score determina os erros de omissão e comissão do algoritmo avaliado, por meio da busca de: 1) estimativa probabilística de predições corretas de rótulos positivos ou negativos; e 2) habilidade de evitar falhas, ou seja, estimativa do complemento da probabilidade de falhas (SOKOLOVA et al., 2006).

$$r = \frac{VP}{VP+FN} \quad (1)$$

$$p = \frac{VP}{VP+FP} \quad (2)$$

$$F = 2 \frac{r.p}{r+p} \quad (3)$$

Em que os valores de VP são os Verdadeiros Positivos (árvores corretamente detectadas pelo algoritmo); FN: Falso Negativo (quando a árvore existe, porém não foi detectada pelo algoritmo); FP: Falso Positivo (quando a árvore não existe, porém, o ponto foi detectado como tal).

O  $r$  (recall) indica a detecção das árvores, ou seja, é um indicador de detecções ou de completude realizadas pelo algoritmo em relação ao alvo de referência. O  $p$  indica a precisão do algoritmo, e também é chamado de correção, que indica a semelhança do alvo detectado pelo algoritmo com a medição de referência. O F-Score é a acurácia geral, levando em consideração os erros de comissão e omissão, sendo que os valores de  $r$ ,  $p$  e F-score variam de 0 a 1, de forma que 1 seja o valor máximo dado para uma segmentação perfeita (LI et al., 2012a). Considera-se como uma boa classificação aquela que obtém valores de  $r$  e  $p$  próximos a 1 (RUTZINGER et al., 2009).

## 2.3 RESULTADOS E DISCUSSÃO

### 2.3.1 Desempenho do DAA nas amostras de treinamento

No plantio jovem não houve necessidade de definir o parâmetro  $H_{\text{dossel}}$ , pois neste estágio o povoamento não apresenta entrelaçamento de copas ainda, consequentemente, não há dossel florestal. O  $r$  por outro lado, foi considerado como o próprio espaçamento do plantio (2,5 metros). Neste plantio, os resultados do algoritmo para as amostras de treinamento podem ser vistos na TABELA 3.

TABELA 3 - RESULTADO DA DETECÇÃO AUTOMÁTICA DE ÁRVORES NAS UNIDADES AMOSTRAIS DO PLANTIO JOVEM DE 2 ANOS.

Bloco	Algoritmo Nº Árv	Ortofoto Nº Árv	VP	FP	FN	r	p	F
UA1	127	141	126	8	13	0,91	0,94	0,92
UA2	145	150	142	1	5	0,97	0,99	0,98
UA3	138	152	137	4	10	0,93	0,97	0,95
Total	410	443	405	13	28	0,94	0,97	0,95

VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score.


Por meio da análise da TABELA 3 é possível observar que o algoritmo obteve bom desempenho identificador, com altas taxas de detecção automática de árvores. De 443 árvores contabilizadas manualmente pela interpretação visual ortofoto, 405 foram detectadas corretamente pelo algoritmo, portanto um percentual de 91% de acerto. A precisão ou correção total obtida (p) foi de 0,97 e a detecção ou completude (r) foi de 0,94, indicando que o algoritmo apresentou menor taxa de detecção, em relação aos seus níveis de precisão. O F-score total das amostras de treinamento foi de 0,95.

Na amostra de treinamento do plantio jovem, pode-se analisar os erros de comissão e omissão cometidos pelo algoritmo. Pela análise, 91% das árvores obtidas pelo DAA foram detectadas automaticamente de forma correta, enquanto que 3% foram erros de comissão e 6% somam os erros de omissão de árvores nas unidades amostrais estudadas.



O resultado da aplicação do algoritmo DAA em uma das unidades amostrais circulares do plantio de árvores pode ser visto na FIGURA 28.

FIGURA 28 - RESULTADO DA APLICAÇÃO DO ALGORITMO DAA EM UMA UNIDADE AMOSTRAL DE PLANTIO JOVEM DE *Pinus spp.*



**Amarelo:** árvores manualmente detectadas pela interpretação manual da ortofoto; **Vermelho:** árvores detectadas automaticamente pelo DAA. FONTE: A autora (2018)

### 2.3.2 Validação do algoritmo de detecção DAA

O resultado da aplicação do algoritmo DAA na nuvem de pontos 3D do plantio jovem pode ser visto na TABELA 4.

TABELA 4 - RESULTADO DA APLICAÇÃO DO DAA EM PLANTIOS JOVENS DE *PINUS SPP.*

Algoritmo								
Bloco	o	Ortofoto	VP	FP	FN	r	p	F
	Nº Arv	Nº Arv						
Talhão	5.722	6.180	5.625	97	555	0,91	0,98	0,95


VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score.

Por meio análise da TABELA, foi verificado que o algoritmo obteve desempenho satisfatório na detecção automática das árvores. Os valores de precisão e detecção foram altos, porém a precisão (p) obtida, de 0,98 foi superior à

detecção ( $r = 0,91$ ). No geral, o F-Score obtido de  $F\text{-score} = 0,95$ , indica o bom desempenho deste método em plantios jovens. No total, 91% das árvores foram corretamente detectadas pelo algoritmo, ao passo que 1,7% do total de pontos detectados pelo algoritmo consistiram em erros de comissão, enquanto que 9% das árvores não puderam ser detectadas, caracterizando erros de omissão do algoritmo apresentado, justificado pelo baixo valor de  $r$ .

A FIGURA 29 mostra o resultado da aplicação do algoritmo na ortofoto do plantio de árvores jovens.

FIGURA 29 - RESULTADO DA SEGMENTAÇÃO AUTOMÁTICA PELO ALGORITMO DAA EM PLANTIO JOVEM DE *Pinus taeda*.



A) DETECÇÃO VISUAL DAS ÁRVORES ATRAVÉS DA FOTOINTERPRETAÇÃO DA ORTOFOTO; B) DETECÇÃO AUTOMÁTICA DAS ÁRVORES PELA AÇÃO DO ALGORITMO; C) CONFRONTAÇÃO DOS RESULTADOS DA INTERPRETAÇÃO VISUAL (AMARELO) E DO ALGORITMO (VERMELHO). FONTE:

O algoritmo DAA, aqui apresentado, subestimou em 7,5% do número total de indivíduos, quando comparado com a ortofoto. Em estudo de inventário de sobrevivência de árvores jovens através da utilização de imagens e VANT e redes neurais artificiais em plantios de eucalipto, Ruza et al. (2017) obteve 4,9% de



superestimava do total de indivíduos contabilizados pela ortofoto, porém utilizando método semiautomático para treinamento dos neurônios, resultando no aumento de custo pessoal e de tempo para realização da segmentação.

Os resultados obtidos pelas análises dos erros de omissão e comissão cometidos pelo algoritmo no povoamento contradiz alguns autores de estudos de detecção automática de árvores (LI et al., 2012; WALLACE; LUCIEER; WATSON, 2014). Tais autores afirmam que conforme o espaçamento entre árvores aumenta, sem entrelaçamento de copas, há grandes chances de superestimativa do valor total do número de indivíduos contabilizados pelo algoritmo. Isto ocorre devido ao aumento da área da copa conforme o espaçamento entre indivíduos aumenta.

Quando a copa é maior que o raio ou a janela de busca estabelecido, há o incremento do número total de árvores, pois uma copa é detectada como duas. No entanto, neste estudo, apesar de não haver entrelaçamento entre copas, com espaçamento entre árvores jovens considerável, não houve problemas de superestimativa, visto que as copas das árvores jovens do plantio de *Pinus spp.* possuem homogeneidade no tamanho, portanto, o raio de busca escolhido para realização da detecção automática de árvores foi condizente com a realidade do plantio.



## 2.4 CONCLUSÃO

O estudo confirmou que a aplicação da nuvem de pontos derivada de imagens ópticas por meio da plataforma RPAS é promissora na detecção de árvores em povoamentos florestais jovens. O nível de detalhamento da nuvem de pontos 3D possibilitou a visualização da estrutura das copas das árvores jovens, aonde a detecção automática por meio do método de máximos globais teve êxito.

O algoritmo proposto apresentou elevadas taxas de detecção ( $r$ ) e altas taxas de precisão ( $p$ ) na detecção das árvores dentro do plantio. Com isto, atendeu as metas de acurácia objetivadas. A alta correlação e acurácia entre o algoritmo e os métodos convencionais de contagem de indivíduos em povoamentos florestais mostrou o potencial da utilização da forma automatizada de contagem. O DAA obteve 91% de acerto em contagem de árvores no plantio jovem. Contudo, é recomendado que o algoritmo seja testado previamente em uma amostra de treinamento para determinar o ajuste de parâmetros de acordo com as características de dossel e espaçamento do plantio, importantes para a redução de erros de omissão e comissão de árvores.

## REFERÊNCIAS

- DANDOIS, J. P.; ELLIS, E. C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**, v. 136, p. 259–276, 2013.
- CHEN, Q. et al. Estimating Basal Area and Stem Volume for Individual Trees from Lidar Data. **Photogrammetric Engineering and Remote Sensing**, v. 73, n. 12, p. 1355–1365, 2007.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.
- HARWIN, S.; LUCIEER, A. an Accuracy Assessment of Georeferenced Point Clouds Produced Via Multi-View Stereo Techniques Applied To Imagery Acquired Via Unmanned Aerial Vehicle. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXIX-B7, n. September, p. 475–480, 2012.
- KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of Individual Tree Crowns in Airborne Lidar Data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 357–367, 2006.
- LESLAR, M. **Integrating Terrestrial Lidar With Point Clouds Created From Unmanned Aerial Vehicle Imagery**. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. **Anais.2015**. Disponível em: <<http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XL-1-W4/97/2015/>>
- LI, W. et al. A New Method for Segmenting Individual Trees from the Lidar Point Cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75–84, 2012.
- RUTZINGER, M.; ROTTENSTEINER, F.; PFEIFER, N. A Comparison of Evaluation Techniques for Building Extraction From Airborne Laser Scanning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 2, n. 1, p. 11–20, 2009.
- RUZA;, M. S. et al. Inventário de Sobrevivência de povoamento de Eucalyptus com uso de Redes Neurais Artificiais em Fotografias obtidas por VANTs. **Advances in Forestry Science**, v. 4, p. 83–88, 2017.
- SKOWRONSKI, N. S. et al. Airborne laser scanner-assisted estimation of aboveground biomass change in a temperate oak-pine forest. **Remote Sensing of Environment**, v. 151, p. 166–174, 2014.
- SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond accuracy, F-Score and ROC: A family of discriminant measures for performance evaluation. **Advances in Artificial Intelligence**, v. 4304, n. c, p. 1015–1021, 2006.

WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 12, p. 7619–7628, 2014.

ZARCO-TEJADA, P. J. et al. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European Journal of Agronomy**, v. 55, p. 89–99, 2014.

### 3 COMPARAÇÃO ENTRE DOIS MÉTODOS DE DETECÇÃO AUTOMÁTICA DE ÁRVORES: A PARTIR DE NUVENS DE PONTOS 3D E FORMATO RASTER

#### RESUMO

Vários métodos para promover detecção automática de árvores a partir de sensores remotos foram criados ao longo dos anos. Muitos destes métodos funcionam a partir de imagens multiespectrais e nuvens de pontos 3D derivadas de Sistemas Laser Aerotransportados. Hoje, a realidade da obtenção remota de informações se faz muitas vezes através de RPAS (*Remotely Piloted Aircraft System*), ou VANT (Veículo Aéreo Não Tripulado). Neste sentido, este trabalho tem por objetivo testar dois algoritmos de detecção automática de árvores, aplicados em dados gerados a partir de imagens ópticas obtidas através sensores: O DAA (Detecção automática de Árvores) e o ITD (*Individual Tree Detection*), cujo primeiro consiste na utilização de nuvens de pontos 3D e o segundo na utilização da nuvem em formato raster. Ambos os algoritmos foram comparados às quantidades de árvores obtidas a partir de levantamento realizado em campo e por fotointerpretação da ortofoto do povoamento. Os testes de acurácia realizados mostraram que o DAA obteve resultados mais satisfatórios que o ITD, em relação ao número total de indivíduos detectados: F-score de 0,93 para o DAA e 0,85 para o ITD. Tal resultado reflete na percentagem de indivíduos detectados em relação ao censo florestal: 95,2% para o DAA e 76,5% para o ITD.

**Palavras chave:** Filtros de máximos locais, Filtros de máximos globais, Contagem de árvores, nuvens de pontos 3D, Imagens ópticas.

## ABSTRACT

Several methods to promote automatic tree detection from remote sensors were created. Many of these methods work from multispectral images and clouds of 3D points derived from Airborne LASER Systems. Today, the reality of remote information retrieval is often done through RPAS (Remotely Piloted Aircraft System), or VANT (Unmanned Aerial Vehicle). In this sense, the objective of this work is to test two automatic tree detection algorithms, applied to data generated from optical images obtained through sensors: *Detecção Automática e Árvores* (DAA) and Individual Tree Detection (ITD) in the use of 3D point clouds and the second in the use of the cloud in raster format. Both algorithms were compared to the quantities of trees obtained from field survey and by photointerpretation of the stand orthophoto. The accuracy tests performed showed that the DAA obtained more satisfactory results than the ITD, in relation to the total number of individuals detected: F-score of 0.93 for the AAD and 0.85 for the ITD. This result reflects the percentage of individuals detected in relation to the forest census: 95.2% for AAD and 76.5% for ITD.

**Keywords:** 3D point clouds. Global maximum filter. Maximum local filter. Tree detection. Optical images.

### 3.1 INTRODUÇÃO

A densidade de árvores em um povoamento florestal é uma informação de extrema relevância para o planejamento da colheita (KOCH; HEYDER; WEINACKER, 2006). Para obtê-la, alguns algoritmos foram desenvolvidos com objetivo de detecção automática de árvores tanto a partir de imagens multiespectrais (WULDER; NIEMANN; GOODENOUGH, 2000) quanto a partir de nuvens de pontos 3D (WALLACE; LUCIEER; WATSON, 2014).

Na abordagem de detecção de árvores em nuvens de pontos 3D, a maioria dos métodos propostos são destinados a aplicação de algoritmo em nuvens de pontos derivadas de Sistema Laser Aerotransportado (LiDAR) (LI et al., 2012; STRAUB; KOCH, 2011; WALLACE; LUCIEER; WATSON, 2014). Muitos destes algoritmos fazem uso da conversão da nuvem tridimensional para o formato raster, e aplicam técnicas de processamento digital de imagens para obtenção automática dos locais referentes ao ápice das copas das árvores (KOCH; HEYDER; WEINACKER, 2006; ZANDONÁ, 2006; WALLACE; LUCIEER; WATSON, 2014; WANG et al., 2008). Entretanto, alguns autores desenvolveram métodos de detecção automática de árvores por meio do uso direto de nuvens de pontos 3D (LI et al., 2012; REITBERGER et al., 2009).

A detecção automática de árvores realizada por meio do modelo digital do dossel, obtido a partir da “*rasterização*” da nuvem de pontos 3D é a mais utilizada e difundida na literatura (MOHAN et al., 2017; WALLACE; LUCIEER; WATSON, 2014). Esta técnica parte do princípio da utilização do método de filtros locais, no qual uma janela de busca pré-estabelecida é aplicada no raster do modelo digital do dossel.

O método de máximos locais apresenta resultados bastante interessantes, porém, Li et al (2012) mostrou ser possível obter resultados mais satisfatórios ao utilizar nuvens de pontos 3D em seu estágio original, através da utilização de filtros de máximos globais para realizar a detecção, quando aplicado diretamente em nuvens de pontos 3D em seu formato original, obtidas de Sistemas LiDAR.

Diante do exposto, este capítulo objetiva comparar a detecção automática de árvores em um plantio adulto homogêneo de *Pinus spp.* por meio da aplicação de dois algoritmos: algoritmo *Individual Tree Detection* (ITD), cujo funcionamento ocorre a partir da aplicação de janelas em raster do modelo digital do dossel através de um filtro de máximos locais, e algoritmo DAA, que trabalha com nuvens de pontos 3D.

Os resultados obtidos foram comparados aos métodos convencionalmente utilizados para contagem de árvores: censo florestal e fotointerpretação.

### 3.2 MÉTODOS

A comparação entre os dois algoritmos de detecção automática de árvores foi realizada a partir de nuvens de pontos 3D de imagens ópticas de RPAS: o *Individual Tree Detection* (ITD), implementado no *software* livre R, por meio do pacote rLidar (SILVA et al., 2005), no qual foi inicialmente desenvolvido para dados de Sistema Laser Aerotransportado (LiDAR) e o DAA (Detecção Automática de Árvores), apresentado nesta dissertação (TABELA 5).

TABELA 5 - CARACTERÍSTICAS DOS DOIS ALGORITMOS DE DETECÇÃO AUTOMÁTICA DE ÁRVORES.

Algoritmo	Nome	Filtro	Entrada	Parâmetros
ITD*	Individual Tree Detection	Filtro de Máximos Locais	Modelo Digital do Dossel - Raster	Janela de busca
DAA	Detecção Automática de Árvores	Filtro de Máximos Globais	Nuvem de pontos 3D	raio de busca - $r$

\* Pacote rLidar.

Os algoritmos foram utilizados para realização de detecção automática de árvores em um plantio adulto de *Pinus spp.* de 11 anos de idade pós desbaste sistemático e seletivo na quinta linha, com densidade final de 750 árvores/ha (FIGURA 30).



FIGURA 30 - IMAGEM EM PERSPECTIVA DO TALHÃO ADULTO UTILIZADO PARA IMPLEMENTAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES.




FONTE: A autora (2018)

### 3.2.1 Algoritmo ITD (Individual Tree Detection)

O algoritmo ITD foi implementado no pacote rLidar por Carlos Alberto Silva et al. (2017), para ser utilizado no *software* de uso aberto R. O algoritmo funciona a partir do uso do algoritmo de filtro de máximos locais (*Local Maximum* – LM), para a realização de identificação automática de árvores a partir do modelo digital do dossel (*Canopy Height Model* - CHM). Originalmente desenvolvido para ser aplicado em dados de nuvens de pontos 3D geradas pelo Sistema Laser Aerotransportado (LiDAR), Mohan et al. (2017) utilizou este pacote para a realização da detecção automática de árvores a partir de nuvens de pontos 3D de imagens ópticas, e obteve resultados satisfatórios, quando empregado em floresta mista nos Estados Unidos.

O ITD utiliza dados de entrada no formato raster do modelo digital do dossel. Portanto, a nuvem de pontos 3D do plantio adulto resultante de todas as fases de pré-processamento mencionado no Capítulo 1, foi transformada para o formato matricial de imagem, sendo que as coordenadas x e y permaneceram as mesmas da nuvem de pontos, e a reflectância do *pixel* do formato de imagem assumiu os valores de z da nuvem de pontos original normalizada. A resolução espacial utilizada para conversão foi de 0,05 metro (FIGURA 31).

FIGURA 31 - A) NUVEM DE PONTOS 3D DO PLANTIO ADULTO ANTES DO PRÉ-PROCESSAMENTO; B) MODELO DIGITAL DO DOSSEL NO FORMATO RASTER.



FONTE: A autora (2018)

Após a obtenção do modelo digital do dossel, foram testadas várias janelas de busca afim de se obter os melhores resultados para o talhão, tal como a metodologia descrita por Mohan et al. (2017). O método de filtro de máximos locais utiliza uma janela móvel de busca de tamanho fixo, para procurar o ápice das árvores na imagem. As janelas testadas neste trabalho foram de tamanho 3 x 3; 5 x 5 e 7 x 7 píxeis.

### 3.2.2 Ajuste dos parâmetros do DAA

No plantio adulto, os blocos BL03 e BL04 foram utilizados como amostras de treinamento para o ajuste dos parâmetros estabelecidos para o DAA. A partir da análise da distribuição dos pontos da nuvem, foi possível obter a informação sobre a  $H_{\text{dossel}}$  (12 metros),  $\text{MaxZ}$  (13 metros) (FIGURA 32) e raio  $r$  foi definido como 1,7 metro (FIGURA 33).

FIGURA 32 - ILUSTRAÇÃO DE COMO É OBTIDO A VARIÁVEL  $H_{\text{DOSSEL}}$  PARA AJUSTE DE PARÂMETRO DO ALGORITMO DAA



fonte:

O raio definido para o ajuste do algoritmo foi fundamentado na distância mínima entre o ápice da copa das árvores, obtida através da medição de algumas árvores aleatórias na ortofoto. Tal distância não é similar ao espaçamento entre árvores, haja vista que no processo de crescimento, os ápices das árvores não indicam exatamente o local da base da árvore, quando projetadas no solo (FIGURA 33).

FIGURA 33 - REPRESENTAÇÃO DA VARIAÇÃO ENTRE A POSIÇÃO DA BASE DA ÁRVORE E O ÁPICE DA COPA.



FONTE: A autora (2018)

### 3.2.3 Avaliação de desempenho dos algoritmos

No plantio adulto, foram realizados 4 tipos de contagem de árvores: censo florestal realizado em campo, contagem por fotointerpretação da ortofoto, detecção automática a partir do ITD e a partir do DAA.

A contagem das árvores em campo por censo florestal foi considerada como o valor real de indivíduos existentes no talhão. A contagem pela ortofoto foi realizada para servir de base para contagem do número de indivíduos passíveis de serem identificados pelas imagens aéreas, e consequentemente pela nuvem de pontos 3D gerada a partir destas, além de fornecer as localizações das árvores em campo, para posterior comparação com as localizações das árvores detectadas pelos algoritmos. As detecções realizadas pelos algoritmos foram comparadas a estes dois métodos de contagem e posteriormente comparados entre si.

O método estatístico utilizado para verificação de completude dos dados foi o mesmo utilizado por Li et al. (2012) e Mohan et al. (2017), nos quais foram calculados os valores de recall (ou completude) ( $r$ ) (Equação 1) precisão (ou correção) ( $p$ ) (Equação 2), e teste F-score (Equação 3). O teste F-Score determina os erros de omissão e comissão do algoritmo avaliado, através da busca de: 1) estimativa probabilística de predições corretas de rótulos positivos ou negativos; e 2) habilidade de evitar falhas, ou seja, estimativa do complemento da probabilidade de falhas (SOKOLOVA et al., 2006).

$$r = \frac{VP}{VP+FN} \quad (1)$$

$$p = \frac{VP}{VP+FP} \quad (2)$$

$$F = 2 \frac{r \cdot p}{r+p} \quad (3)$$

Onde os valores de VP são os Verdadeiros Positivos (árvores corretamente detectadas pelo algoritmo); FN: Falso Negativo (quando a muda existe, porém não

foi detectada pelo algoritmo); FP: Falso Positivo (quando a muda não existe, porém, o ponto foi detectado como tal).

O *r* (recall) indica a detecção das árvores, ou seja, é um indicador de detecções ou de completude realizadas pelo algoritmo em relação ao alvo de referência. O *p* indica a precisão do algoritmo, e também é chamado de correção, que indica a semelhança do alvo detectado pelo algoritmo com a medição de referência. O F-Score é a acurácia geral, levando em consideração os erros de comissão e omissão, sendo que os valores de *r*, *p* e F-score variam de 0 a 1, de forma que 1 seja o valor máximo dado para uma segmentação perfeita (LI et al., 2012a). Considera-se como uma boa classificação aquela que obtém valores de *r* e *p* próximos a 1 (RUTZINGER et al., 2009).


### 3.3 RESULTADOS E DISCUSSÃO

#### 3.3.1 Detecção de árvores a partir do algoritmo ITD

A partir de vários testes de tamanhos ideais de janelas de busca fixa, a que apresentou melhores resultados foi a de dimensão 3 x 3, para o algoritmo ITD, exemplificado na FIGURA 34.

FIGURA 34 - DETECÇÃO AUTOMÁTICA DAS ÁRVORES A PARTIR DO ALGORITMO ITD E CONTAGEM VISUAL PELA FOTOINTERPRETAÇÃO DA ORTOFOTO.






▲ Árvores identificadas visualmente

● Árvores detectadas pelo ITD

FONTE: A autora (2018)

Os resultados de detecção automática de árvores obtidos pelo algoritmo ITD para o talhão podem ser vistos na FIGURA 35 (Fonte dos dados: Anexo TABELA 1).

FIGURA 35 - RESULTADO DA DETECÇÃO AUTOMÁTICA DE ÁRVORES PELO ALGORITMO ITD EM TODOS OS BLOCOS DO TALHÃO ESTUDADO DE 11 ANOS



VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score.

FONTE: A autora (2018)

O F-score obtido a partir da detecção de árvores pelo algoritmo com base em máximas locais foi de 0,85. Entretanto, o ITD apresentou altos valores de precisão (p), de 0,95. Os valores de completude (r) foram baixos, tendo atingido a

média de 0,78 apenas, indicando que o ITD possui baixa taxa de detecção, porém com bons índices de acertos das árvores corretamente detectadas. Consideradas apenas as árvores corretamente identificadas pelo algoritmo (1.767 árvores), 75% correspondem à contagem realizada pela fotointerpretação pela ortofoto e 71% à contagem realizada pelo censo florestal.

Os erros de comissão (FP) e omissão (FN) em relação à contagem pela ortofoto são também mostrados na FIGURA 35. No total, dos 1.892 pontos identificados como árvores, 5,4% (102 pontos) foram classificados como falsos positivos, ou seja, os pontos detectados não correspondem a árvores. Das 2.359 árvores conferidas na ortofoto, 26,16% (495 árvores) não puderam ser identificadas pelo algoritmo ITD.

Os resultados obtidos são comparáveis aos encontrados em Mohan et al. (2017), no qual obteve F-Score para o algoritmo ITD de 0,86 em um povoamento misto de coníferas e folhosas. Disperati et al. (2007) ao aplicar o filtro de máximos locais em fotografias aéreas em uma área florestal homogênea com a espécie *Pinus elliottii* desbastada sistematicamente, chegou a uma acurácia de 70,7% em relação número de indivíduos contabilizados na ortofoto (706), de um total de 726 levantados em campo. Koch et al. (2006) ao utilizar este tipo de filtro para obter detecção automática de árvores a partir de Laser aerotransportado em florestas obteve 87,3% de acertos em árvores corretamente detectadas em comparação àquelas informações coletadas em campo, porém os autores relatam que a maioria dos erros de omissão são em decorrência das árvores suprimidas do povoamento.

### 3.3.2 Detecção de árvores a partir do algoritmo DAA

O processamento do algoritmo de máximas globais nas amostras de treinamento resultou em uma acurácia de 0,94, de um intervalo de 0 a 1 (TABELA 6), quando comparado ao número de árvores contabilizadas por interpretação visual na ortofoto.



TABELA 6 - RESULTADO DA APLICAÇÃO DO ALGORITMO DE DETECÇÃO AUTOMÁTICA DE ÁRVORES NAS AMOSTRAS DE TREINAMENTO DO PLANTIO ADULTO DE *PINUS SPP.* DE 11 ANOS. .

Bloco	Número de árvores		Censo	VP	FP	FN	r	p	F
	Algoritmo	Ortofoto							
BL03	278	270	249	258	20	12	0,96	0,93	0,94
BL04	252	237	269	231	21	6	0,97	0,92	0,94
Total	530	507	518	489	41	18	0,96	0,92	0,94

VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score.

A aplicação do algoritmo resultou na detecção de 530 árvores, em um total de 507 árvores detectadas manualmente por meio da fotointerpretação da ortofoto e 518 contabilizadas no censo, indicando que o método proposto quando aplicado nestes dois blocos apresentou casos de detecção de falsos positivos. Das 530 árvores detectadas automaticamente, 489 foram segmentadas corretamente em relação à contagem manual por ortofoto, representando um percentual de 96% de acertos. E 94,4% de árvores corretamente detectadas quando comparadas a contabilização por censo florestal. Os resultados visuais da detecção dos blocos 03 e 04 estão ilustrados na FIGURA 36.

FIGURA 36 - Processo de detecção automática de árvores em nuvens de pontos de imagens ópticas nas amostras de treinamento.




A) Nuvem de pontos antes da detecção; B) Árvores detectadas a partir do Raio  $R$ ; C) Obtenção do ponto mais alto referente a cada árvore da amostra; D) Resultado final da detecção automática de árvores na amostra de treinamento adicionado à ortofoto. E) Detalhe do resultado da detecção na ortofoto. FONTE: A autora (2018)

Quando aplicado no talhão, a acurácia obtida pelo algoritmo de DAA foi de 0,93 (F-Score), em relação a contagem manual das árvores, e 93% de porcentagem de acerto de árvores corretamente detectadas (FIGURA 37). O coeficiente F-Score indica o nível de acurácia do algoritmo com base nos acertos, taxas de omissão e comissão. Neste estudo, o F-Score obteve valor semelhante ao encontrado por Li et

al. (2012), no qual obteve F-Score = 0,90, e por Wallace et al. (2014), onde as árvores foram corretamente detectadas em 92% a 97% do total do povoamento. (para valores numéricos ver Anexo: TABELA 2).

FIGURA 37 - RESULTADO DA DETECÇÃO AUTOMÁTICA DE ÁRVORES PELO ALGORITMO DAA EM TODOS OS BLOCOS DO TALHÃO ESTUDADO DE 11 ANOS.



VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score.

FONTE: A autora (2018)


Os valores totais de detecção (ou completude) ( $r$ ) e de precisão (ou correção) ( $p$ ) foram semelhantes (0,93), indicando que o algoritmo DAA possui alto desempenho no que diz respeito à detecção das árvores e com alto nível de precisão. Ao levar em consideração que 2.192 árvores foram segmentadas corretamente pelo algoritmo DAA, isto representa 89% do total contabilizado pelo censo florestal, e a interpretação visual obteve 95,4% de acerto em relação ao censo. Por outro lado, 6,96% do total das árvores (164) foram detectados erroneamente e 7,09% não foram detectadas pelo algoritmo (167 árvores), resultando em falsos positivos e falsos negativos respectivamente.

### 3.3.3 Comparação entre métodos

Os resultados obtidos para os quatro métodos de contagem de árvores em plantio adulto de *Pinus spp.* são apresentados no gráfico da FIGURA 38. O censo florestal foi utilizado como referência para o número total de árvores existentes no talhão. O método da fotointerpretação serviu de base para obtenção da quantidade

de árvores que é possível contabilizar remotamente, apenas a partir das fotografias aéreas. As quantidades de árvores obtidas a partir dos algoritmos DAA e ITD foram comparadas aos dois métodos de referência, para verificação de qual obteve melhores resultados.

FIGURA 38 - RESULTADO DA CONTAGEM DE ÁRVORES EM PLANTIO FLORESTAL HOMOGÊNEO DE *Pinus* spp DE 11 ANOS. ATRAVÉS DE QUATRO MÉTODOS DISTINTOS: CENSO FLORESTAL, FOTOINTERPRETAÇÃO, ALGORITMO ITD E ALGORITMO DAA.



FONTE: A autora (2018)


A partir da FIGURA 38, e utilizando a contagem pelo censo e pela ortofoto como referência, foi possível constatar que o algoritmo ITD apresentou resultados com subestimativas do número total de árvores em todos os blocos (1.892 de 2.474 árvores). Já o algoritmo DAA, com base no método de máximos globais, apresentou resultado mais próximo aos obtidos pelo método de censo florestal (2.356 de 2.474 árvores), e pelo resultado obtido pela ortofoto (2.359). Pela contagem da ortofoto não foi possível contabilizar a totalidade dos indivíduos no talhão, isto se deve à dificuldade de marcação do ápice das árvores, principalmente quando há o entrelaçamento entre copas, portanto, sob estas condições, as interpretações torna-se muitas vezes subjetivas por parte do fotointérprete (DISPERATI et al., 2007).

A partir da FIGURA 38, ainda é observável que o DAA apresentou melhores valores para a contagem de número de indivíduos, em relação ao ITD. Quando levado em consideração a contagem pelo censo florestal apenas, o DAA obteve valores de 95,2% de acerto para a totalidade dos pontos detectados e 88,6% para os pontos verdadeiramente identificados como árvores. Já o ITD apresentou valores

de 76,5% quando considerado todos os pontos obtidos e 71,4% quando considerado apenas as árvores verdadeiras positivas. O algoritmo DAA subestimou a quantidade de indivíduos no povoamento, devido a nuvens de pontos derivadas de imagens ópticas representar apenas a parte visível representadas nas fotografias aéreas, diferente da nuvem obtida por laser aéreo (sensor ativo). Portanto é comum que árvores dominadas estejam oclusas, assim como o efeito de sombreamento nas imagens resulta na perda de algumas informações de copa em relação ao dossel florestal.

O algoritmo DAA apresentou maiores valores de acurácia (F-score) em relação ao ITD. A menor taxa de acerto obtida pelo teste F-Score em ambos os algoritmos ocorreu no Bloco 12. Neste, apenas 9 árvores puderam ser identificadas pelo algoritmo DAA, 7 pelo ITD, e 16 pela ortofoto. Em contrapartida, no censo florestal foram contabilizadas 24 árvores. O erro de omissão cometido pelos algoritmos neste bloco pode ter ocorrido em consequência da sua localização, situado no limite entre o talhão e um remanescente de floresta nativa, no qual há oclusão e sombreamento de algumas árvores nas fotografias aéreas, devido a diferença hipsométrica e de textura entre uma floresta nativa e um povoamento homogêneo. Disperati et al. (2007) relata este mesmo problema na divisão entre reflorestamento de pinus e vegetação nativa, para contabilização das árvores de pinus nos limites entre as vegetações, pela ortofoto. A ocorrência de sombras e oclusões em decorrência do remanescente de floresta nativa pode ser o elemento restritivo na obtenção da nuvem de pontos a partir das imagens ópticas, uma vez que a qualidade das imagens exerce inteira influência na obtenção da nuvem de pontos 3D e na ortofoto.

FIGURA 39 - DETECÇÃO AUTOMÁTICA DAS ÁRVORES A PARTIR DOS MÉTODOS DE FOTOINTERPRETAÇÃO, ALGORITMO ITD E DAA.




FONTE: A autora (2018)

A partir do exemplo da FIGURA 39, percebe-se que a maioria das árvores detectadas de forma automática obteve resultado condizente com o contabilizado por fotointerpretação. Em alguns casos houveram árvores não detectadas por nenhum dos algoritmos, da mesma forma como houveram muitas árvores detectadas apenas pelo algoritmo DAA. Isto porque irregularidades encontradas nos tamanhos das copas influenciam negativamente no desempenho dos algoritmos em áreas de grande densidade de árvores (MOHAN et al., 2017). Portanto, as características do dossel e consequentemente o espaçamento de plantio influenciam o resultado da detecção de árvores (REITBERGER et al., 2009).

No geral, os erros de omissão e comissão cometidos pelos algoritmos apresentaram padrões já relatados na literatura. Tanto no algoritmo DAA quanto no ITD, os erros de omissão estão associados a árvores cujas copas não detectadas encontram-se entrelaçadas ou suprimidas; já os erros de comissão geralmente aumentam com o espaçamento, pois os galhos geralmente são mais prolongados, e ocasionam a adição de uma ou mais árvores (WALLACE; LUCIEER; WATSON, 2014). Mohan et al. (2017) afirma ainda que, no caso do algoritmo ITD, o sucesso depende do diâmetro e da altura das árvores. Afirma também que árvores vizinhas mais baixas possuem ápice com baixa reflectância e contraste, acarretando a não identificação destas copas pelo algoritmo de máximos locais (FIGURA 40).



FIGURA 40 - A) DETALHAMENTO DOS CASOS DE FALSOS NEGATIVOS (ERROS DE OMISSÃO) COMETIDOS PELO ALGORITMO EM ÁRVORES SUPRIMIDAS; B) DETALHAMENTO DOS CASOS DE FALSOS POSITIVOS (ERROS DE COMISSÃO) COMETIDOS PELO ALGORITMO EM ÁRVORES DOMINANTES COM COPAS EXTENSAS E PROLONGADAS.



FONTE: A autora (2018)

A FIGURA 40 – A ilustra os erros de omissão de indivíduos suprimidos pelas árvores vizinhas, e como consequência, os algoritmos entendem que a árvore menor expressa o prolongamento de copa de uma árvore vizinha dominante, ou que não possui reflectância e contraste suficiente no raster para ser identificada como árvore, assim como na FIGURA 40 – B a copa de árvores mais altas são mais prolongadas, extrapolando os limites do raio preestabelecidos para busca, ou das janelas de busca, em consequência, há a adição de árvores onde elas não existem, criando falsos positivos.

Uma importante observação que pode ser feita sobre a estrutura da nuvem de pontos utilizada para o teste do algoritmo proposto é o fato de ser derivada de povoamentos homogêneos com espaçamentos regulares de uma espécie do gênero *Pinus*. Vários estudos sobre segmentação automática de árvores, tanto por meio de dados *laser* quanto imagens ópticas, apontam que coníferas possuem estrutura de copa que facilita a ação da segmentação. Sperlich et al. (2014) ao analisar a aplicação de um algoritmo de detecção automática de árvores em nuvem de pontos derivados de dados ópticos, constatou que apenas 30% das árvores folhosas de referência foram segmentadas com êxito, enquanto que mais de 90% das coníferas puderam ser segmentadas.

A densidade da nuvem processada influenciou diretamente no processamento do algoritmo DAA. Assim, optou-se em utilizar apenas 1% do total de pontos das nuvens para obtenção de tempo de processamento hábil para uso.

### 3.4 CONCLUSÃO

O estudo comparativo entre os dois algoritmos de detecção automática que árvores que funcionam a partir de princípios diferentes mostrou que o algoritmo DAA, cujo funcionamento se dá a partir do método de máximos globais, aplicado na nuvem de pontos 3D normalizada, apresentou resultados mais condizentes com os levantamentos de campo e contabilização do número de árvores pela ortofoto, em comparação ao algoritmo ITD, cujo funcionamento se dá a partir do princípio de máximos locais, aplicado no raster do modelo digital do dossel.

Os valores de F-score obtidos dos dois algoritmos mostraram que o DAA obteve acurácia superior ao ITD. Entretanto, o algoritmo ITD apresentou maiores valores de precisão que o DAA, ou seja, apesar do reduzido número de árvores detectados pelo algoritmo ITD, a precisão deste foi melhor que a apresentada pelo DAA.

A partir do estudo foi possível observar que mesmo pela contagem de árvores pela ortofoto não foi possível obter o número total de árvores contabilizada pelo censo florestal, visto que as imagens não capturam a totalidade de árvores existentes no dossel, devido a problemas de oclusão.

Para ambos os algoritmos estudados neste capítulo, há a necessidade de definição de parâmetros para seu funcionamento adequado, e obtenção da quantidade e localização de árvores com maiores níveis de precisão no povoamento.



## REFERÊNCIAS

- DISPERATI, A. A. et al. Aplicação da técnica “filtragem de locais máximas” em fotografia aérea digital para a contagem de copas em reflorestamento de *Pinus elliottii*. **Scientia Forestalis/Forest Sciences**, n. 76, p. 45–55, 2007.
- KIM, D.; RUDEMO, MA. Stem number estimation by kernel smoothing os aerial photos. **Canadian Journal of Forest Research**, v. 26, p. 1228–1236, 1997.
- KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of Individual Tree Crowns in Airborne Lidar Data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 357–367, 2006.
- LI, W. et al. A New Method for Segmenting Individual Trees from the Lidar Point Cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75–84, 2012.
- MOHAN, M. et al. Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. **Forests**, v. 8, n. 9, p. 340, 2017.
- REITBERGER, J. et al. 3D segmentation of single trees exploiting full waveform LIDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 6, p. 561–574, 2009.
- RUTZINGER, M.; ROTTENSTEINER, F.; PFEIFER, N. A Comparison of Evaluation Techniques for Building Extraction From Airborne Laser Scanning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 2, n. 1, p. 11–20, 2009.
- SILVA, Carlos A.; CROOKSON, Nicholas L. HUDAK, Andrew T. Hudak; VIERING, Lee A.; KLAUBERG, Carine. **LiDAR Data Processing and Visualizaion**. R Package 'rLiDAR'. 2017.
- KATTENBORN, T. et al. Automatic single palm tree detection in plantations using UAV-based photogrammetric point clouds. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 40, n. 3, p. 139–144, 2014.
- STRAUB, C.; KOCH, B. Estimating single tree stem volume of *Pinus sylvestris* using airborne laser scanner and multispectral line scanner data. **Remote Sensing**, v. 3, n. 5, p. 929–944, 2011.
- WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 12, p. 7619–7628, 2014.
- WANG, Y. et al. Lidar point cloud based fully automatic 3D single tree modelling in forest and evaluations of the procedure. **The International Archives of the**

**Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVII, n. June 2008, p. 45–52, 2008.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. Local maximum filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. **Remote Sensing of Environment**, v. 73, n. 0, p. 103–114, 2000.

ZANDONÁ, D. F. Potencial uso de dados laser scanner aerotransportado para estimativa de variáveis dendrométricas. p. 82, 2006.

#### 4 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

As nuvens de pontos 3D obtidas a partir de imagens aéreas ópticas de RPAS apresentaram alta densidade e riqueza de detalhamento no dossel florestal de *Pinus* spp. adulto e jovem, detalhamento este que não é obtido a partir da rasterização da nuvem de pontos. Por meio da metodologia de voo adotada para obtenção de imagens foi possível extrair o modelo digital do terreno de ambos os plantios, e com alta densidade de pontos, possibilitando sucesso no processo de normalização das nuvens.

A aplicação do DAA na nuvem de pontos 3D de imagens ópticas possibilita obter níveis aceitáveis de completude na detecção do número de indivíduos, para ambos os plantios estudados. O algoritmo DAA (Detecção Automática de Árvores) proposto neste trabalho possibilitou a detecção de forma automática de árvores no plantio adulto de 89% em relação ao censo florestal e 93% em relação à contagem por ortofoto. No plantio jovem, a taxa de detecção foi de 91%.

Quando submetido à comparação entre algoritmos de detecção de árvores relatados na literatura, como o ITD (*Individual Tree Detection*), que funciona com base nos princípios de máximos locais, aplicado no formato rasterizado da nuvem de pontos 3D, o DAA (Detecção Automática de Árvores) apresentou melhores resultados para o plantio adulto estudado. O DAA obteve percentuais de acerto em relação às contagens pelo censo florestal e ortofoto bastante superiores ao outro algoritmo (95,2% do total de árvores contabilizadas pelo censo, em comparação a 76,5% do ITD).

A detecção automática de árvores realizada através do algoritmo DAA mostrou poder haver taxas relevantes de detecção de falsas árvores e árvores verdadeiras, principalmente quando analisado o povoamento adulto. Tal fato está estreitamente relacionado com o ajuste dos parâmetros estabelecidos no povoamento e na qualidade do voo realizado com RPAS. Deve-se ter precaução em ajustá-los, uma vez que, como já mencionado, o espaçamento nem sempre é o melhor parâmetro fornecido. É indicado realizar medições prévias manuais de distância entre copas na ortofoto do povoamento para obter o melhor ajuste dos parâmetros, para resultar em melhor performance do algoritmo. No plantio jovem, o espaçamento pode ser utilizado para ajuste, por não existir entrelaçamento de copas.

As recomendações gerais para trabalhos e estudos futuros com a tecnologia de nuvens de pontos 3D de imagens ópticas em áreas florestais são basicamente: fazer levantamentos aéreos em dias com boa luminosidade, nos horários entre 10h00 e 14h00 para minimizar os efeitos de sombreamento nas imagens aéreas; realizar voos com alturas adequadas ao espaço-objeto e planejamento de voo com alta taxa de sobreposição; Para utilização do algoritmo DAA para obtenção automática do número de indivíduos: reamostrar a nuvem de pontos 3D para redução de custo computacional; ajustar os parâmetros de entrada da melhor forma possível para evitar subestimativas ou superestimativas do número total de árvores.

Para obter melhores resultados para obtenção do número de indivíduos de uma população, é aconselhável que após a obtenção dos resultados do DAA, se faça uma checagem visual para contagem das possíveis árvores não identificadas pelo método automático.

## REFERÊNCIAS

- ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138–146, 2013.
- BEIS, J. S.; LOWE, D. G. Shape indexing using approximate nearest-neighbour search in high-dimensional. **Computer Vision and Pattern Recognition, 1997. Proceedings.** p. 1000-1006, 1997.
- BROWN, M.; LOWE, D. G. Recognising Panoramas. **Department of Compute Science.** University of British Columbia. Vancouver, Canada. 2002.
- CHEN, Q. et al. Estimating Basal Area and Stem Volume for Individual Trees from Lidar Data. **Photogrammetric Engineering and Remote Sensing**, v. 73, n. 12, p. 1355–1365, 2007.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.
- DANDOIS, J. P. et al. What is the point? Evaluating the structure, color, and semantic traits of computer vision point clouds of vegetation. **Remote Sensing**, v. 9, n. 4, p. 1–20, 2017.
- DANDOIS, J. P.; ELLIS, E. C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**, v. 136, p. 259–276, 2013.
- DISPERATI, A. A. et al. Aplicação da técnica “filtragem de locais máximas” em fotografia aérea digital para a contagem de copas em reflorestamento de *Pinus elliottii*. **Scientia Forestalis/Forest Sciences**, n. 76, p. 45–55, 2007.
- FRITZ, A.; KATTENBORN, T.; KOCH, B. UAV-BASED PHOTOGRAMMETRIC POINT CLOUDS -TREE STEM MAPPING IN OPEN STANDS IN COMPARISON TO TERRESTRIAL LASER SCANNER POINT CLOUDS. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XL-1/W2, n. September, p. Pages: 141-146, 2013.
- GAVA, Christiano. Dense 3D Reconstruction. 2011. Technische Universität KaisersLaurern, Lecture 3D computer vision. KaisersLaurern.
- GEBRESLASIE, M. T. et al. Individual tree detection based on variable and fixed window size local maxima filtering applied to IKONOS imagery for even-aged Eucalyptus plantation forests. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4141–4154, 2011.
- GETZIN, S.; NUSKE, R. S.; WIEGAND, K. Using Unmanned Aerial Vehicles (UAV) to Quantify Spatial Gap Patterns in Forests. p. 6988–7004, 2014.

HARTLEY, R., GUPTA, R. AND CHANG, T. Stereo from uncalibrated cameras, Proc. IEEE Conf. Comp. Vision Patt. Recog., Champaign, IL, pp. 761-764, 1992.

HARTLEY, R.; ZISSERMAN, A. **Multiple View Geometry**. New York: United States of America, 2004. v. 53

HARWIN, S.; LUCIEER, A. an Accuracy Assessment of Georeferenced Point Clouds Produced Via Multi-View Stereo Techniques Applied To Imagery Acquired Via Unmanned Aerial Vehicle. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXIX-B7, n. September, p. 475–480, 2012.

HARWIN, S.; LUCIEER, A.; OSBORN, J. The impact of the calibration method on the accuracy of point clouds derived using unmanned aerial vehicle multi-view stereopsis. **Remote Sensing**, v. 7, n. 9, p. 11933–11953, 2015.

JIANG, H. et al. Papaya Tree Detection with UAV Images Using a GPU-Accelerated Scale-Space Filtering Method. **remote sensing Article**, v. 9, n. 721, p. 1–13, 2017.

KATTENBORN, T. et al. Automatic single palm tree detection in plantations using UAV-based photogrammetric point clouds. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 40, n. 3, p. 139–144, 2014.

KERSTING, J. et al. Filtragem de Modelos Digitais de Superfície derivados da varredura a laser usando a triangulação de Dalaunay. **I Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação - SIMGEO**, v. 1, n. Burrough 1986, p. 1–10, 2004.

KIM, D.; RUDEMO, MA. Stem number estimation by kernel smoothing os aerial photos. **Canadian Journal of Forest Research**, v. 26, p. 1228–1236, 1997.

KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of Individual Tree Crowns in Airborne Lidar Data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 357–367, 2006.

LESLAR, M. **Integrating Terrestrial Lidar With Point Clouds Created From Unmanned Aerial Vehicle Imagery**. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. **Anais.2015**. Disponível em: <<http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XL-1-W4/97/2015/>>

LI, W. et al. A New Method for Segmenting Individual Trees from the Lidar Point Cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75–84, 2012.

LOWE, D. G. Object recognition from local scale-invariant features. **International Journal of Computer Vision**. p. 1150 - 1157, 1999.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, v. 60, n. 2, p. 91–110, 2004.

MIRANDA, G. H. B. **ANÁLISE DE AMOSTRAGEM E INTERPOLAÇÃO NA GERAÇÃO**. [s.l.] Universidade Federal de Viçosa, 2017.

MOHAN, M. et al. Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. **Forests**, v. 8, n. 9, p. 340, 2017.

MULAC, B. L. Remote sensing applications of unmanned aircraft: challenges to flight in United States airspace. **Geocarto International**, v. 26, n. 2, p. 71–83, 2011.

NEX, F.; REMONDINO, F. UAV for 3D mapping applications: a review. **Appl Geomat**, p. 1–15, 2014.

PULITI, S. et al. Inventory of Small Forest Areas Using an Unmanned Aerial System. p. 9632–9654, 2015.

REITBERGER, J. et al. 3D segmentation of single trees exploiting full waveform LIDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 6, p. 561–574, 2009.

RUSU, R. B. et al. Towards 3D Point cloud based object maps for household environments. **Robotics and Autonomous Systems**, v. 56, n. 11, p. 927–941, 2008.

RUTZINGER, M.; ROTTENSTEINER, F.; PFEIFER, N. A Comparison of Evaluation Techniques for Building Extraction From Airborne Laser Scanning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 2, n. 1, p. 11–20, 2009.

RUZA, M. S. et al. Inventário de Sobrevivência de povoamento de Eucalyptus com uso de Redes Neurais Artificiais em Fotografias obtidas por VANTs. **Advances in Forestry Science**, v. 4, p. 83–88, 2017.

SHAHBAZI, M. et al. Uav-Based Point Cloud Generation for Open-Pit Mine Modelling. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XL-1/W4, p. 313–320, 2015.

SILVA, Carlos A.; CROOKSON, Nicholas L. HUDAK, Andrew T. Hudak; VIERING, Lee A.; KLAUBERG, Carine. **LiDAR Data Processing and Visualizaion**. R Package 'rLiDAR'. 2017.

SKOWRONSKI, N. S. et al. Airborne laser scanner-assisted estimation of aboveground biomass change in a temperate oak-pine forest. **Remote Sensing of Environment**, v. 151, p. 166–174, 2014.

SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond accuracy, F-Score and ROC: A family of discriminant measures for performance evaluation. **Advances in Artificial Intelligence**, v. 4304, n. c, p. 1015–1021, 2006.

SIEBERT, S.; TEIZER, J. Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system. **Automation in Construction**, v. 41, p. 1–14, 2014.



SOTIER, B. High resolution aerial images from UAV for forest applications State-of-the-Art. **Alpine Space. Project**, v. 232FR, n. 2, 2014.

STRAUB, C.; KOCH, B. Estimating single tree stem volume of *Pinus sylvestris* using airborne laser scanner and multispectral line scanner data. **Remote Sensing**, v. 3, n. 5, p. 929–944, 2011.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. Springer ed. London: Springer-Verlag London, 2011.

TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, p. 791–797, 2015.

TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 2012.

WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 12, p. 7619–7628, 2014.

WANG, Y. et al. Lidar point cloud based fully automatic 3D single tree modelling in forest and evaluations of the procedure. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVII, n. June 2008, p. 45–52, 2008.

WANG, Y.; WEINACKER, H.; KOCH, B. A Lidar point cloud based procedure for vertical canopy structure analysis and 3D single tree modelling in forest. **Sensors**, v. 8, n. 6, p. 3938–3951, 2008.

WEB OF SCIENCE. Disponível em: <<https://webofknowledge.com/>>. Acessado em 25 de fevereiro de 2018.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. Local maximum filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. **Remote Sensing of Environment**, v. 73, n. 0, p. 103–114, 2000.

XIANG, H.; TIAN, L. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle ( UAV ). **Biosystems Engineering**, v. 108, n. 2, p. 174–190, 2011.

DISPERATI, A. A. et al. Aplicação da técnica “filtragem de locais máximas” em fotografia aérea digital para a contagem de copas em reflorestamento de *Pinus elliottii*. **Scientia Forestalis/Forest Sciences**, n. 76, p. 45–55, 2007.

KIM, D.; RUDEMO, MA. Stem number estimation by kernel smoothing os aerial photos. **Canadian Journal of Forest Research**, v. 26, p. 1228–1236, 1997.

KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of Individual Tree Crowns in Airborne Lidar Data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 357–367, 2006.

LI, W. et al. A New Method for Segmenting Individual Trees from the Lidar Point Cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75–84, 2012.

MOHAN, M. et al. Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. **Forests**, v. 8, n. 9, p. 340, 2017.

REITBERGER, J. et al. 3D segmentation of single trees exploiting full waveform LIDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 6, p. 561–574, 2009.

RUTZINGER, M.; ROTTENSTEINER, F.; PFEIFER, N. A Comparison of Evaluation Techniques for Building Extraction From Airborne Laser Scanning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 2, n. 1, p. 11–20, 2009.

SILVA, Carlos A.; CROOKSON, Nicholas L. HUDAK, Andrew T. Hudak; VIERING, Lee A.; KLAUBERG, Carine. **LiDAR Data Processing and Visualizaion**. R Package 'rLiDAR'. 2017.

KATTENBORN, T. et al. Automatic single palm tree detection in plantations using UAV-based photogrammetric point clouds. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 40, n. 3, p. 139–144, 2014.

STRAUB, C.; KOCH, B. Estimating single tree stem volume of *Pinus sylvestris* using airborne laser scanner and multispectral line scanner data. **Remote Sensing**, v. 3, n. 5, p. 929–944, 2011.

WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 12, p. 7619–7628, 2014.

WANG, Y. et al. Lidar point cloud based fully automatic 3D single tree modelling in forest and evaluations of the procedure. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVII, n. June 2008, p. 45–52, 2008.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. Local maximum filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. **Remote Sensing of Environment**, v. 73, n. 0, p. 103–114, 2000.

ZANDONÁ, D. F. Potencial uso de dados laser scanner aerotransportado para estimativa de variáveis dendrométricas. p. 82, 2006.

ZARCO-TEJADA, P. J. et al. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European Journal of Agronomy**, v. 55, p. 89–99, 2014.

ZHANG, W. et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. **Remote Sensing**, v. 8, n. 6, p. 1–22, 2016.

ZHENGYOU, Z. Determining the epipolar geometry and its uncertainty: a review. **International Journal of Computer Vision**. v. 27. p. 161 - 198, 1997.

**ANEXO 1 – TABELA COM RESULTADOS DA DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DO ALGORITMO ITD (*Individual Tree Detection*).**

Bloco	ITD Nº Arv	Ortofoto Nº Arv	Censo Nº Arv	VP	FP	FN	r	p	F
BL01	64	96	110	52	5	44	0,542	0,912	0,68
BL02	157	184	198	137	4	43	0,761	0,972	0,854
BL03	211	270	249	205	6	59	0,777	0,972	0,863
BL04	212	237	269	199	13	25	0,888	0,939	0,913
BL05	199	240	257	186	13	41	0,819	0,935	0,873
BL06	217	249	259	195	22	32	0,859	0,899	0,878
BL07	199	243	253	191	8	44	0,813	0,96	0,88
BL08	184	234	238	175	9	50	0,778	0,951	0,856
BL09	174	221	226	166	8	47	0,779	0,954	0,858
BL10	168	205	208	159	9	37	0,811	0,946	0,874
BL11	100	164	183	96	4	64	0,6	0,96	0,738
BL12	7	16	24	6	1	9	0,4	0,857	0,545
Total	1.892	2.359	2.474	1.767	102	495	0,781	0,945	0,855

VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score.

**ANEXO 2 – TABELA COM RESULTADOS DA DETECÇÃO AUTOMÁTICA DE ÁRVORES A PARTIR DO ALGORITMO DAA (*Detecção Automática de Árvores*).**

Bloco	DAA Nº Arv	Ortofoto Nº Arv	Censo Nº Arv	VP	FP	FN	r	p	F
BL01	88	96	110	88	0	8	0,92	1	0,96
BL02	181	184	198	173	8	11	0,94	0,96	0,95
BL03	278	270	249	258	20	12	0,96	0,93	0,94
BL04	252	237	269	231	21	6	0,97	0,92	0,94
BL05	241	240	257	224	17	16	0,93	0,93	0,93
BL06	258	249	259	240	18	9	0,96	0,93	0,95
BL07	268	243	253	232	36	11	0,95	0,87	0,91
BL08	226	234	238	217	9	17	0,93	0,96	0,94
BL09	216	221	226	206	10	15	0,93	0,95	0,94
BL10	203	205	208	191	12	14	0,93	0,94	0,94
BL11	136	164	183	123	13	41	0,75	0,9	0,82
BL12	9	16	24	9	0	7	0,56	1	0,72
Total	2.356	2.359	2.474	2.192	164	167	0,93	0,93	0,93

VP: Verdadeiro Positivo; FP: Falso Positivo; FN: Falso Negativo; r: recall; p: precisão; F: F-score